

部分空間を用いた脳波識別のための空間フィルタの設計

鷺沢研究室所属

1331114

善本 秀法

2015 年 1 月

概 要

脳コンピュータインターフェイス (BCI) とは、観測された脳信号から機器の操作命令を作り出すインターフェイスである。P300-based BCI は被験者に刺激を与えたときに誘発される P300 の有無によって、脳活動の判別を行う BCI である。P300-based BCI には空間重みを用いた特徴抽出法である空間フィルタを適用する手法が提案されている。本研究では、空間重みを求める問題に対して、射影ノルムと投影距離を用いた手法とそれらをカーネル化した手法を提案する。前者は P300 部分空間へのクラス間の射影ノルムと投影距離の比を、後者はカーネル非線形 P300 部分空間への射影ノルムと投影距離の比を最大にするものである。2 つの P300-based BCI のデータセットを用いて、提案手法と従来手法の比較実験を行った。実験結果よりカーネル非線形 P300 部分空間への射影ノルムを用いた手法が、比較したどの手法よりも高い識別率であるということを統計検定で示した。

目次

第1章 序論	6
1.1 はじめに	6
1.2 本論文で用いる記号表記	8
1.3 論文構成	8
第2章 従来手法	9
2.1 P300	9
2.2 空間フィルタ	9
2.3 PCA	10
2.4 LDA	10
2.5 部分空間類別法	11
2.5.1 CLAFIC 法	12
2.5.2 投影距離法	13
2.5.3 CLAFIC 法と投影距離法の違い	13
2.6 特異値分解	14
2.7 従来手法	15
2.7.1 事前定義	15
2.7.2 C-FMS beamformer	15
2.7.3 特徴抽出	17
第3章 提案手法	19
3.1 従来手法の問題点	19
3.2 提案手法1	19
3.2.1 P300 部分空間	19
3.2.2 空間フィルタの設計	20
3.3 提案手法2	20
3.3.1 空間フィルタの設計	20
3.4 線形部分空間を用いた空間フィルタの問題点	21
3.5 カーネル関数	21
3.6 提案手法3	21
3.6.1 カーネル非線形 P300 部分空間を用いた非線形部分空間の構成	22
3.6.2 空間フィルタの設計	23
3.7 提案手法4	23
3.7.1 カーネル共分散行列	23

3.7.2	空間フィルタの設計	24
3.8	空間フィルタによる特徴抽出	24
第4章	データセット	26
4.1	聴性 BCI	26
4.2	P300 speller	26
第5章	実験方法	29
5.1	前処理	29
5.2	特徴ベクトル	29
5.3	PCA による次元削減と特徴抽出	29
5.4	LDA による識別	30
5.5	評価方法	30
5.5.1	交差検定	30
5.5.2	分散分析	31
5.5.3	多重比較検定	31
5.6	t 検定	32
5.7	パラメータ	32
第6章	実験結果	34
6.1	識別率	34
6.2	最適パラメータ	34
6.3	検定	34
6.4	頭皮上マッピング	34
第7章	考察とまとめ	39
7.1	結果の考察	39
7.2	今後の課題	39
7.3	本論文の成果	41

図 目 次

1.1	P300-based BCI の例	7
2.1	P300 の例	10
2.2	CLAFIC 法の例	18
2.3	投影距離法の例	18
4.1	聴性 BCI のデータセットの音声呈示方法	27
4.2	スピーカ配置図	27
4.3	電極配置図	28
4.4	P300 speller の刺激呈示方法	28
5.1	実験手順の概要	30
6.1	被験者 1 の頭皮上マッピング	36
6.2	被験者 2 の頭皮上マッピング	36
6.3	被験者 3 の頭皮上マッピング	36
6.4	被験者 4 の頭皮上マッピング	36
6.5	被験者 5 の頭皮上マッピング	37
6.6	被験者 6 の頭皮上マッピング	37
6.7	被験者 7 の頭皮上マッピング	37
6.8	被験者 8 の頭皮上マッピング	37
6.9	被験者 A の頭皮上マッピング	38
6.10	被験者 B の頭皮上マッピング	38

表 目 次

6.1	識別結果	35
6.2	最適パラメータ	35
6.3	多重比較検定の結果 (補正 p 値)	35

第1章 序論

1.1 はじめに

脳コンピュータインターフェイス (BCI; Brain Computer Interface)) は観測された脳信号から思考や刺激による脳活動の判別を行うことで、機器の操作命令を作り出すインターフェイスである [1]。BCI は身体の動きを伴わないインターフェイスを実現できるため、重度の筋萎縮性側索硬化症患者 (ALS; Amyotrophic Lateral Sclerosis) などの脳機能のみが残存している人が自らの意思で機器の操作を行ったり、他者と意思疎通したりすることを可能にする有望な技術である。BCI はユーザに与える刺激やユーザに課すタスクによって様々な種類のものが提案されている。

脳活動を計測するには大きく分けて2つの方法が存在する。1つは開頭して計測装置を脳の中に設置する方法であり、侵襲計測と呼ばれる。代表的なものとして、微小電極計測 (MEM; Micro-Electrode Measurement) や光計測 (OR; Optical Recording) などが挙げられる。侵襲計測はノイズが少なく正確なデータが計測でき、マウス、ネコ、サルなどの脳活動の計測に主に使われる。しかし、感染症や失敗したときのリスクが大きく、倫理的な問題も発生することが多いため計測すること自体が難しい。

もう1つは開頭しない計測方法であり、非侵襲計測と呼ばれる [2]。非侵襲的な脳活動の計測には脳波計 (EEG; Electroencephalograph) や、脳磁計 (MEG; Magnetoencephalograph)、機能的磁気共鳴画像装置 (fMRI; Functional Magnetic Response Imaging) といった計測装置がよく用いられる。EEG は比較的安価で小さな装置で計測できるが、fMRI や MEG などは比較的高価で大きい。それゆえに、特に BCI においては、計測の簡易性からよく EEG が用いられる。

EEG を用いた BCI には、周期的な視覚刺激によって誘発される定常的視覚誘発電位 (SSVEP; Steady State Visual Evoked Potentials) に基づくもの [4]、周期的な聴覚刺激によって誘発される定常的聴覚誘発電位 (ASSR; Auditory Stady State Response) に基づくもの [3]、 μ リズムの脱同期に基づくもの [1]、記憶や認識に関連した刺激によって誘発される事象関連電位 (ERP; Event Related Potential) に基づくものなどがある [1]。

ERP の1つに P300 がある [6]。P300 とは人が何かを認知した約 300ms 後に現れる脳波の成分である。P300-based BCI は P300 の特性を利用し、P300 の有無を EEG から判別することで利用者の要求を推定する BCI である。図 1.1 に P300-based BCI の例を示す。P300-based BCI は刺激に反応するだけでコマンドを発行できるため、操作するために訓練が必要なく、他の BCI と比べてコマンドを容易に発行できるという長所を持っている。P300-based BCI の例として、視覚刺激に反応するだけで文字入力 [10] や車椅子の操作 [11] ができるものや、聴覚刺激に反応するだけで簡単なコマンドを入力できるものなどが挙げられる。

P300-based BCI は被験者がどの試行のどの刺激に対しても同じタイミングで反応し、同じ

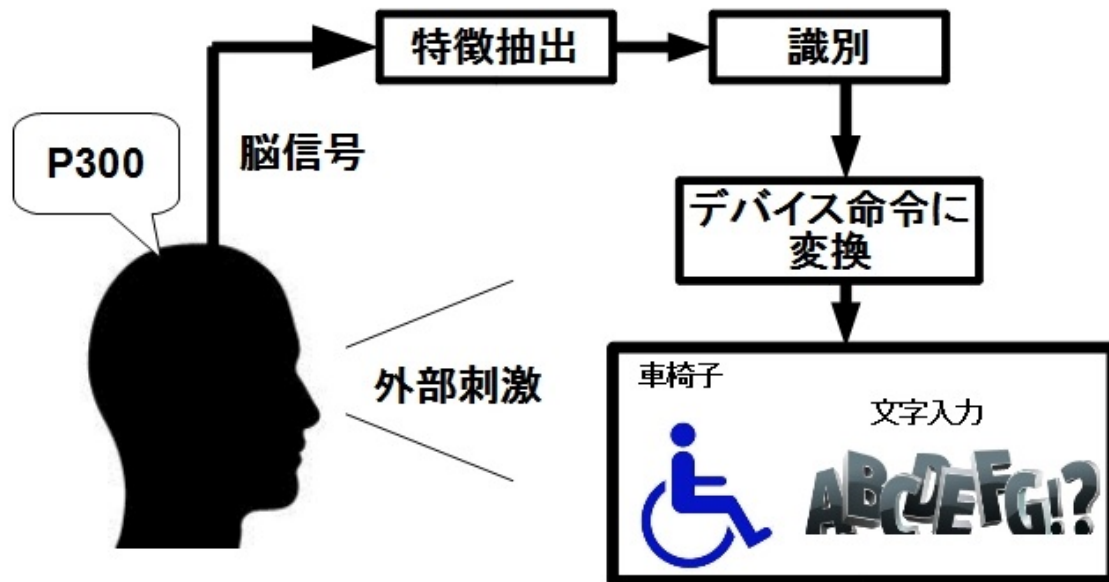


図 1.1: P300-based BCI の例: 外部刺激には視覚を用いたものが一般的である。

特徴を持った P300 を発生させることを前提としている．そして，その前提の下で観測信号を加算平均し，背景雑音を消すという手法がよく用いられている．しかし，実際には被験者の精神状態や刺激に対する集中の度合いによって脳波に大きな差が出ることが知られている．例えば，少しでも目や体を動かすと筋電が，精神的にリラックスしたり集中しているとアルファ波やベータ波などの自発脳波が雑音として EEG に含まれる可能性がある．また，刺激の種類によって認知のタイミングが異なれば，それらの差は雑音となる．これらの雑音は P300-based BCI の識別精度の向上を妨げるため，影響を減らすための様々なフィルタが提案されている．空間フィルタは抽出する情報を制限することにより，特徴ベクトルに用いる次元を削減することができるという長所を持っている．空間フィルタは特徴抽出が電極に依存するため，運動想像 BCI のような，各電極ごとに違った特徴が見られる時によく用いられる．また，空間重みの値を用いて，どの電極の信号が識別に有効であったかを調べることができる．

P300-based BCI に使う空間フィルタとして CSP (Common Spatial Pattern) や，FDA (Fisher Discriminant Analysis)，CCA (Canonical Correlation Analysis) の手法を基にしたものが提案されている [12][13]．例えば，Rivet らの手法では xDAWN アルゴリズムを基に被験者の SSNR (Signal to Signal-plus-Noise Ratio) を最大にする空間フィルタを提案している [13]．その他にも Pires らは CSP と FDA を基にした空間フィルタを組み合わせた C-FMS beamformer (Cascades the Fisher criterion beamformer with the Max-SNR beamformer) や CSP を特徴抽出に用いた P300-based BCI の解析方法を提案している [12][15]．

また，カーネル関数を用いた空間フィルタとして，Nasihatkon などがカーネル CSP を提案している [16][17]．カーネル CSP では EEG は線形識別が難しい非線形な信号であると考えており，それらをうまく識別するために非線形のカーネル関数を用いた空間フィルタを用いて EEG の非線形性を吸収したり，高次元空間への写像をすることを提案している．

本論文では新たな P300-based BCI の空間フィルタとして，射影ノルムと投影距離を用いた空間フィルタと，それらにカーネル関数を用いて拡張した空間フィルタを提案する．これらは

観測信号に P300 の特徴がどれぐらい含まれているかを示す基準として射影ノルムや投影距離を用いて特徴抽出を行うものである．具体的には P300 を含む信号を用いて分布を特徴づける部分空間を求め、P300 を含む信号と含まない信号の部分空間への射影ノルム、または投影距離の比を最大にする空間フィルタを設計する手法である．さらに、P300 を含む信号に非線形のカーネル関数を用いてカーネル非線形 P300 部分空間を求め、P300 を含む信号と含まない信号の部分空間への射影ノルム、または投影距離の比を最大にする空間フィルタを設計する手法も提案する．提案手法はどちらも部分空間を基に空間フィルタを設計するために安定していること、パラメータの数が多いためにより詳細な解析ができることが長所として挙げられる．

提案する各フィルタの特徴として、射影ノルムを用いた空間フィルタは特徴空間の原点と各クラスの部分空間との相対位置に特徴抽出が依存するが、投影距離を用いた空間フィルタは部分空間を構成するときの原点を各クラスの中心に置くため、特徴空間の原点と各クラスの部分空間との相対位置に特徴抽出が依存しないということが挙げられる．さらに、それらをカーネルに拡張した空間フィルタでは、カーネル関数を介した非線形変換を用いた部分空間を構成するため、観測信号の分布が非線形な軸に沿って広がる場合に対しても有効であり、また、特徴空間を高次元にするため、各クラスの部分空間同士の重なりを減らすことができるという特徴も持つことが考えられる．

2つの P300-based BCI のデータセットを用いた実験によって、提案する空間フィルタが P300-based BCI の識別に有効であることを示す．そのために、従来手法として空間フィルタを用いない手法と C-FMS beamformer を用いて、提案手法と比較実験を行った．また、識別時の空間フィルタの重み係数を用いて、どの電極の信号が識別に有効であったかを調べた．

1.2 本論文で用いる記号表記

本論文では、数字とスカラー定数はローマン体、スカラー変数はイタリック体、ベクトルと行列と作用素はボールドイタリック体で表し、 \mathbf{A}^T は行列 \mathbf{A} の転置を、 \mathbf{B}^* は作用素 \mathbf{B} の共役作用素を表す．また、 \mathbb{R} は実数集合、 \mathcal{H} はヒルベルト空間を表す．

1.3 論文構成

本論文の構成は、以下の通りである．第1章ではBCI全般についての説明から始まり、本論文で提案する新たな空間フィルタについての紹介を述べる．第2章では空間フィルタや従来手法について述べる．第3章では本論文で提案する空間フィルタについて述べている．第4章ではデータセットについて述べる．第5章では実験手順や評価方法などの実験構成について述べる．第6章では実験で得られた実験結果について述べる．第7章では本研究の成果や今後の課題を述べる．第8章では今後の課題について述べる．

第2章 従来手法

この章では、従来手法の原理である P300 と空間フィルタについて述べた後、解析手法の原理である Principal component analysis (PCA) と Linear discriminant analysis (LDA) について述べ、その後に提案手法の原理となる Class-Featuring Information Compression method (CLAFIC 法) と投影距離法と特異値分解について述べ、最後に従来手法の一つとして C-FMS beamformer について述べる。

2.1 P300

P300 は ERP の一種で多くの BCI で被験者の脳活動の判断基準として用いられている。P300 は刺激を被験者に呈示したときに頭頂部付近で誘発される正の電位であり、刺激呈示後 300ms 付近で観測されることから P300 と呼ばれている。図 2.1 に P300 の例を示す。図 2.1 は刺激が呈示されてから 0.5 秒までの脳波を表している。

P300 を効果的に観測することができる手続きとして、オドボール課題が挙げられる [6]。オドボール課題では、被験者に、頻度の異なる 2 種類以上の刺激をランダムに呈示し、低頻度で出現する刺激が呈示されたときに声を出さずにその回数を数える、またはボタンを押すなどの課題を課す。このような課題を被験者に課すと、低頻度の刺激が呈示された時に P300 が強く誘発される。

P300 を検出するための手続きとして、加算平均法がよく用いられる。これは、P300 は刺激呈示後 300ms 付近で現れるのに対して、その他の成分の脳波は時間に関係なく現れるため、背景雑音を消すことができるためである [25]。

2.2 空間フィルタ

P300-based BCI の研究では、特徴ベクトルは各電極から得られた信号を連結させて構成することが多い。しかし、全ての電極の観測信号を連結させて特徴ベクトルを構成すると、次元が大きくなるため、判別精度が下がったり、識別器の学習や識別に時間がかかってしまう恐れがある。そのため、識別を行う前に次元を削減することがしばしば行われる。

その次元削減の方法の 1 つとして、空間フィルタが挙げられる。空間フィルタは、識別に有効な情報を各電極の EEG の重み付き線形和によって抽出する方法であり、以下の式で表される。

$$y(t) = \sum_{i=1}^N \omega_i x_i(t) \quad (2.1)$$

ここで、 ω_i は空間重み、 N はチャンネル数、 $x_i(t)$ は i 番目の電極から得られる脳波信号である。




図 2.1: P300 の例: 50 回分の脳波の加算平均の波形. 8 チャンネル. 被験者は低頻度刺激を意識している. P300 が観測できる.

空間フィルタには教師なしのものと教師ありのものがあり, それぞれ用途に応じて様々なものが提案されている. 教師なしの空間フィルタには独立成分分析や主成分分析, CCA をもとにした手法などがある. 一方, 教師ありの空間フィルタは, 訓練データを学習させることで, 判別に有効な成分を抽出する方法であり, CSP や FDA を基にした手法などがある.

2.3 PCA

PCA とは主部分空間と呼ばれる低次元の線形空間へのデータ点の分散を最大化させる直交射影として定義される [29]. 主部分空間は自己相関行列の固有値分解を用いて求めることができる. PCA は次元削減, 非可逆データ圧縮, 特徴抽出, データの可視化などに広く適用される手法であり, Karhunen-Loève 変換 (KL 変換) としても知られている [29].

2.4 LDA

PCA は特徴ベクトルを表現する有効な方向を見出す手法であるが, LDA は判別にとって有効な方向を探す手法である [24]. 具体的には, 射影した結果がなるべく良く分離されて重なりが最小となる最良の方向 ω' を求めることである [24]. ω' は以下の評価関数を最大にする ω で

ある.

$$J(\omega) = \frac{\omega^T \mathbf{S}_B \omega}{\omega^T \mathbf{S}_W \omega} \quad (2.2)$$

ここで \mathbf{S}_W はクラス内分散行列, \mathbf{S}_B はクラス間分散行列である. ここで, \mathbf{S}_W は $\mathbf{S}_W = \mathbf{S}_1 + \mathbf{S}_2$ であり, $\mathbf{S}_1, \mathbf{S}_2$ は

$$\mathbf{S}_c = \frac{1}{|\Omega_c|} \sum_{\mathbf{f}_i \in \Omega_c} (\mathbf{f}_i - \mathbf{m}_c)(\mathbf{f}_i - \mathbf{m}_c)^T \quad c = 1, 2 \quad (2.3)$$

として求める. ここで \mathbf{f}_i は i 番目の特徴ベクトル, Ω_c はクラス c の信号の集合である. また, \mathbf{S}_B は

$$\mathbf{S}_B = (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^T \quad (2.4)$$

であり, $\mathbf{m}_1, \mathbf{m}_2$ は, 以下のようにして求める.

$$\mathbf{m}_c = \frac{1}{|\Omega_c|} \sum_{\mathbf{f}_i \in \Omega_c} \mathbf{f}_i \quad c = 1, 2 \quad (2.5)$$

式 (2.2) の一般化固有値問題は次のように考えることもできる. \mathbf{S}_W が正則であれば,

$$\mathbf{S}_W^{-1} \mathbf{S}_B \omega = \lambda \omega \quad (2.6)$$

と変形して通常の固有値問題となり,

$$\omega \propto \mathbf{S}_W^{-1}(\mathbf{m}_1 - \mathbf{m}_2) = (\mathbf{S}_1 + \mathbf{S}_2)^{-1}(\mathbf{m}_1 - \mathbf{m}_2) \quad (2.7)$$

が成り立つ. 評価関数を最大にする ω を求めるだけならば, ω の倍率は重要ではないので $\mathbf{S}_W^{-1} \mathbf{S}_B$ の固有値と固有ベクトルを求める必要はない. すると, 評価関数 J を最大にする ω' は直ちに

$$\omega' = \mathbf{S}_W^{-1}(\mathbf{m}_1 - \mathbf{m}_2) = (\mathbf{S}_1 + \mathbf{S}_2)^{-1}(\mathbf{m}_1 - \mathbf{m}_2) \quad (2.8)$$

として求めることができる.

LDA を用いた識別は, 具体的には未知のパターンベクトルを \mathbf{x} とすると, 定数項 b を加えて, $\omega'^T \mathbf{x} + b > 0$ ならば, \mathbf{x} はクラス 1, $\omega'^T \mathbf{x} + b < 0$ ならば, \mathbf{x} はクラス 2 として識別できる.

2.5 部分空間類別法

部分空間類別法は各クラスごとにそのクラスを表現する低次元の部分空間を形成し, 未知の信号がどの部分空間でもっともよく近似できるかを比較することにより未知の信号を識別する手法である [21]. CLAFIC 法や投影距離法は部分空間類別法の一つである.

2.5.1 CLAFIC 法

CLAFIC 法は各クラス分布ごとにクラス部分空間を決定し、未知のパターンのクラス部分空間への射影ノルムが最大となる部分空間のクラスに判定する方法である [20].

C 個のクラスのそれぞれの部分空間を $\mathbf{L}_1, \mathbf{L}_2, \dots, \mathbf{L}_c, \dots, \mathbf{L}_C$, その次元を $d_1, d_2, \dots, d_c, \dots, d_C$ とする. 各クラスについて, 部分空間 \mathbf{L}_c を張る d_c 次元正規直交ベクトルを $\mathbf{u}_{c,1}, \dots, \mathbf{u}_{c,d_c}$ とする. このとき, $\mathbf{u}_{c,k}$ の正規直交性により,

$$\mathbf{u}_{c,k}^T \mathbf{u}_{c,l} = \delta_{k,l} \quad (2.9)$$

となる. このとき, $\delta_{k,l}$ はクロネッカーのデルタである. CLAFIC 法ではこの正規直交ベクトル $\mathbf{u}_{c,k}$ を PCA を用いて求める. 具体的にはクラス c の自己相関行列の固有ベクトルを用いる. クラス c に属する d 次元特徴ベクトルを \mathbf{f}_{c,i_c} とすると, クラス c の自己相関行列 \mathbf{R}_c は

$$\mathbf{R}_c = \frac{1}{I_c} \sum_{i_c} \mathbf{f}_{c,i_c} \mathbf{f}_{c,i_c}^T \quad (2.10)$$

となる. ここで, i_c はクラス c に対するサンプル数のインデックスであり, I_c はその総数である.

次にクラス c に着目し, d 次元特徴空間から d_c 部分空間への変換行列を \mathbf{A}_c とすると

$$\mathbf{A}_c = [\mathbf{u}_{c,1}, \dots, \mathbf{u}_{c,d_c}] \quad (2.11)$$

と書ける. そして, 元の空間から部分空間 \mathbf{L}_c への変換は直交射影行列

$$\mathbf{P}_c = \mathbf{A}_c \mathbf{A}_c^T = \sum_{j=1}^{d_c} \mathbf{u}_{c,j} \mathbf{u}_{c,j}^T \quad (2.12)$$

によって表すことができる. また, 未知ベクトル \mathbf{x} の部分空間 \mathbf{L}_c への正射影は $\mathbf{P}_c \mathbf{x}$ であり, その射影ノルム $\|\mathbf{P}_c \mathbf{x}\|^2$ は

$$\|\mathbf{P}_c \mathbf{x}\|^2 = \mathbf{x}^T \mathbf{P}_c \mathbf{P}_c \mathbf{x} = \mathbf{x}^T \mathbf{P}_c \mathbf{x} \quad (2.13)$$

となる.

CLAFIC 法では, 未知ベクトル \mathbf{x} と部分空間とのなす角の余弦 θ_c を識別基準に用いる. 具体的には,

$$\cos^2 \theta_c = \sum_{j=1}^{d_c} \frac{(\mathbf{x}, \mathbf{u}_{c,j})^2}{\|\mathbf{x}\|^2 \|\mathbf{u}_{c,j}\|^2} \quad (2.14)$$

が識別基準となる. ここで, $\|\mathbf{u}_{c,j}\|^2$ は正規直交ベクトルであるため, どの j に対しても 1 であり, また, $\|\mathbf{x}\|^2$ は c や j によらず一定であるので識別基準は

$$\cos^2 \theta_c \propto \sum_{j=1}^{d_c} (\mathbf{x}, \mathbf{u}_{c,j})^2 = \|\mathbf{P}_c \mathbf{x}\|^2 \quad (2.15)$$

と書き直すことができる. つまり, 射影ノルムは未知ベクトル \mathbf{x} とクラス c との類似度とみなすことができ, この類似度を $S_c(\mathbf{x})$ とすると,

$$S_c(\mathbf{x}) = \mathbf{x}^T \mathbf{P}_c \mathbf{x} \quad (2.16)$$

となる．CLAFIC 法では未知ベクトル \mathbf{x} はこの類似度が最大になる部分空間のクラスに識別される．

2.5.2 投影距離法

投影距離法とは各クラス重心を起点として，各クラス分布ごとにクラス部分空間を決定し，未知のパターンのクラス部分空間への投影距離が最小となる部分空間のクラスに判定する方法である [19]．投影距離とは，単純距離や重みつき距離の問題点を解消するために案された距離の概念であり，単純距離や重みつき距離と比べて，データ間の相関が存在する場合も考慮し，分散の小さいデータの誤差の影響が小さくすることを目的とした距離である [19]．具体的には投影距離は入力サンプルとカテゴリを表現する部分空間との距離によって定義される．

まず，以下のようにしてクラス c の共分散行列 \mathbf{C}_c を求める．

$$\mathbf{C}_c = \frac{1}{I_c} \sum_{i_c}^{I_c} (\mathbf{f}_{c,i_c} - \mathbf{m}_c)(\mathbf{f}_{c,i_c} - \mathbf{m}_c)^T \quad (2.17)$$

ここで \mathbf{m}_c はクラス c に属する特徴ベクトルの平均である．次に \mathbf{C}_c に対して固有値分解を行う．そのときの，第 k 固有ベクトルを $\phi_{c,k}$ とする．

未知ベクトル \mathbf{x} に対して，投影距離は以下のように定義される．

$$D_c = \|\mathbf{x} - \mathbf{m}_c\|^2 - \sum_{j=1}^k (\mathbf{x} - \mathbf{m}_c, \phi_{c,j})^2 \quad (2.18)$$

これは未知ベクトルと $\phi_{c,k}$ で構成された各クラスの部分空間との擬距離を表す．また，

$$\|\mathbf{x} - \mathbf{m}_c\|^2 = \sum_{j=1}^d (\mathbf{x} - \mathbf{m}_c, \phi_{c,j})^2 \quad (2.19)$$

であるから，投影距離は

$$D_c = \|\mathbf{x} - \mathbf{m}_c\|^2 - \sum_{j=1}^k (\mathbf{x} - \mathbf{m}_c, \phi_{c,j})^2 \quad (2.20)$$

$$= \sum_{j=k+1}^d (\mathbf{x} - \mathbf{m}_c, \phi_{c,j})^2 \quad (2.21)$$

と表すことができる．つまり，投影距離とは補空間への射影量でもあることがわかる．

投影距離法では未知ベクトル \mathbf{x} は投影距離が最小となるクラスに分類される．また， $k = 0$ と置くと，識別結果は単純距離法と一致する．

2.5.3 CLAFIC 法と投影距離法の違い

図 2.2 と 2.3 にそれぞれ CLAFIC 法と投影距離法の例を示す．このとき，特徴ベクトルの次元は x_1, x_2, x_3 の 3 次元であり，部分空間の次元は 2 次元である．また，図 2.3 中の \mathbf{V}_c は $\mathbf{V}_c = \sum_{j=1}^2 \phi_{c,j} \phi_{c,j}^T$ である．CLAFIC 法は図 2.2 のベクトル $\mathbf{P}_c \mathbf{x}$ の大きさを，投影距離法で

は図 2.3 の線分 \overline{XH} の長さを基準に \mathbf{x} のクラスを判別する．全ての c に対して \mathbf{m}_c が 0 であるならば，投影距離法と CLAFIC 法の識別結果は一致する．

2つの手法の大きな違いは2つある．まず一つは，CLAFIC 法は特徴ベクトルと部分空間との相違を余弦で評価するが，投影距離法は幾何学的距離で評価することである．もう一つは CLAFIC 法は部分空間を構成するときの原点を特徴空間の原点に置くが，投影距離法は各クラスの重心に置くことである．そのため，各クラスの分布が特徴空間の原点をまたいでいる場合，CLAFIC 法はうまく機能しないという欠点を持っている．しかし，一般的には CLAFIC 法と投影距離法の識別性能の差を結論付けることはできない [19][21]．

2.6 特異値分解

特異値分解は行列分解の一手法であり，正方行列に限らず任意の長方形行列を分解することができる [14]．また，特異値分解を応用すると，実際には必要のない，固有値が 0 の固有ベクトルに対する計算を省くことができるため，固有値分解に関する計算の効率化によく用いられる [14]．

任意の $a \times b$ 行列 \mathbf{F} を用いて，行列 \mathbf{A} と \mathbf{B} を $\mathbf{A} = \mathbf{F}\mathbf{F}^T$ ， $\mathbf{B} = \mathbf{F}^T\mathbf{F}$ とする．このとき，行列 \mathbf{A} と \mathbf{B} は半正値対称行列であるから，0 でない固有値はすべて正となる．また，2つの行列は共通の固有値と 0 でない固有値の個数 (ランク) を持つ．このランクを $\text{rank}(\mathbf{F}) = r$ とする．

\mathbf{A} の固有値を大きい順に並べ $\lambda_1, \dots, \lambda_r, \dots, \lambda_a$ とし，それに対応する固有ベクトルを $\mathbf{u}_1, \dots, \mathbf{u}_a$ とし，それらを並べた行列を

$$\mathbf{U}_a = [\mathbf{u}_1, \dots, \mathbf{u}_a] \quad (2.22)$$

とする．同様に行列 \mathbf{B} の固有値を大きい順に並べ $\lambda_1, \dots, \lambda_r, \dots, \lambda_b$ とし，それに対応する固有ベクトルを $\mathbf{v}_1, \dots, \mathbf{v}_b$ とし，それらを並べた行列を

$$\mathbf{V}_b = [\mathbf{v}_1, \dots, \mathbf{v}_b] \quad (2.23)$$

とする．すると，行列 \mathbf{A} と \mathbf{B} の固有ベクトルの関係性は以下のように表わされる．

$$\mathbf{u}_s = \frac{\mathbf{F}\mathbf{v}_s}{\sqrt{\lambda_s}}, \quad \mathbf{v}_s = \frac{\mathbf{F}^T\mathbf{u}_s}{\sqrt{\lambda_s}} \quad (2.24)$$

このとき， s は固有値に対するインデックスであり， $s = 1, \dots, r$ である．上式の関係性を用いると， $\mathbf{F}\mathbf{V}_b$ は

$$\begin{aligned} \mathbf{F}\mathbf{V}_b &= [\mathbf{F}\mathbf{v}_1, \dots, \mathbf{F}\mathbf{v}_b] = [\sqrt{\lambda_1}\mathbf{u}_1, \dots, \sqrt{\lambda_r}\mathbf{u}_r, 0, \dots, 0] \\ &= \mathbf{U}_a\mathbf{\Sigma}, \quad \mathbf{\Sigma} = \begin{bmatrix} \sqrt{\lambda_1} & & & \\ & \ddots & & \\ & & \sqrt{\lambda_r} & \\ & & & \end{bmatrix} \end{aligned} \quad (2.25)$$

と表すことができる．ここで， Σ は左上が $r \times r$ の対角行列であり，その他の要素が0である $a \times b$ 行列である．さらに， V_b は直交行列であり， $V_b V_b^T = I$ であるから，上式は

$$F = U_a \Sigma V_b^T$$

と書き直すことができる．ここで，上式の行列の計算の中で0の固有値との計算は必要なく，必要のある計算はランク r までの固有値とそれに対応する固有ベクトルの計算である．よって， F は， $U_r = [u_1, \dots, u_r]$ ， $V_r = [v_1, \dots, v_r]$ とすると，

$$F = U_r \begin{bmatrix} \sqrt{\lambda_1} & & \\ & \ddots & \\ & & \sqrt{\lambda_r} \end{bmatrix} V_r^T \quad (2.26)$$

として求めることができる．これを行列 F に対する特異値分解と呼ぶ．また， $\sqrt{\lambda_1}, \dots, \sqrt{\lambda_r}$ を特異値と呼ぶ．

2.7 従来手法

ここでは，従来手法の一つとして教師あり空間フィルタの設計方法である C-FMS beamformer について述べる．

2.7.1 事前定義

観測信号 $x_{i,N_{ch}}(t)$ に対し，行列 \mathbf{X}_i とベクトル $\mathbf{x}_{i,N_{ch}}$ を以下のように定義する．

$$\mathbf{X}_i = \begin{bmatrix} x_{i,1}(0) & \cdots & x_{i,1}(T-1) \\ \vdots & \ddots & \vdots \\ x_{i,N}(0) & \cdots & x_{i,N}(T-1) \end{bmatrix} \quad (2.27)$$

$$\mathbf{x}_{i,N_{ch}} = [x_{i,N_{ch}}(0), \dots, x_{i,N_{ch}}(T-1)]^T \quad (2.28)$$

ここで， $i = 1, \dots, I$ ， $N_{ch} = 1, \dots, N$ であり， I は試行数， T は刺激が呈示されてから 0.5 秒までのサンプリング点， N はチャンネル数を示す．そして，P300 が含まれている信号の集合を Ω_1 ，P300 が含まれていない信号の集合を Ω_2 とする．

2.7.2 C-FMS beamformer

教師ありの空間フィルタはいくつか提案されているが，本研究では Pires らが提案した SN 比と Fisher criterion (FC) を最大にする空間フィルタを組み合わせた特徴抽出方法である C-FMS beamformer を従来手法の 1 つとして比較実験を行う．

FC 最大フィルタ

このフィルタはクラス内の分散を最小にしながら、クラス間の分離を最大にすることを目的とする。そして、その基準として FC を用いている。具体的には、FC は P300 の信号と P300 が含まれていない信号の空間パターンの違いを表す。FC を最大化することはクラス間の空間パターンの差異を最大化することであり、P300 のみならず、それに付随する脳波の成分の強調にもつながると考えられる。

FC 最大フィルタは以下の評価関数を最大にする ω として定義される。

$$J(\omega) = \frac{\mathbf{w}^T \mathbf{S}_b \mathbf{w}}{\mathbf{w}^T \mathbf{S}_w \mathbf{w}} \quad (2.29)$$

ここで、 \mathbf{S}_b は空間クラス間分散行列、 \mathbf{S}_w は空間クラス内分散行列であり、以下のように表される。

$$\mathbf{S}_b = \sum_{m=1}^2 \frac{|\Omega_m|}{|\Omega_1| + |\Omega_2|} (\bar{\mathbf{X}}_m - \bar{\mathbf{X}})(\bar{\mathbf{X}}_m - \bar{\mathbf{X}})^T \quad (2.30)$$

$$\mathbf{S}_w = \sum_{m=1}^2 \sum_{\mathbf{X}_i \in \Omega_m} (\mathbf{X}_i - \bar{\mathbf{X}}_m)(\mathbf{X}_i - \bar{\mathbf{X}}_m)^T \quad (2.31)$$

このとき、 $\bar{\mathbf{X}}_m$ と $\bar{\mathbf{X}}$ は

$$\bar{\mathbf{X}}_m = \frac{1}{|\Omega_m|} \sum_{\mathbf{X}_i \in \Omega_m} \mathbf{X}_i, \quad m = 1, 2 \quad (2.32)$$

$$\bar{\mathbf{X}} = \frac{1}{|\Omega_1| + |\Omega_2|} \sum_i \mathbf{X}_i \quad (2.33)$$

である。式 (2.29) に正則化項を足した、

$$\mathbf{S}_b \mathbf{w} = \lambda[(1 - \theta)\mathbf{S}_w + \theta \mathbf{I}] \mathbf{w}, \quad 0 \leq \theta \leq 1 \quad (2.34)$$

の最大一般化固有値に対応する一般化固有ベクトルを $\hat{\mathbf{W}}_1$ とする。このとき、 θ は正則化パラメータである。また、式 (2.34) で得られる最大一般化固有値以外の固有値を大きい順に並べ、それに対応する固有ベクトルを合わせた行列を \mathbf{W}_1 とする。

SN 比最大フィルタ

この空間フィルタは P300 の信号に対するノイズ除去問題とみなして設計する。具体的には、P300 のクラスの信号を S(Signal)、そうでないクラスの信号を N(Noise) とみなして、出力 SN 比を最大にする空間フィルタを設計する。SN 比最大フィルタは以下の評価関数を最大にする ω として定義される。

$$J(\omega) = \frac{\mathbf{w}^T \hat{\mathbf{R}}_1 \mathbf{w}}{\mathbf{w}^T \hat{\mathbf{R}}_2 \mathbf{w}} \quad (2.35)$$

ここで、評価関数 J は出力 SN 比を表している。 $\hat{\mathbf{R}}_1$ と $\hat{\mathbf{R}}_2$ はそれぞれ P300 が含まれている信号の共分散行列、P300 信号が含まれていない信号の共分散行列であり、信号の出力を表して

いる．共分散行列は以下のように表される．

$$\hat{\mathbf{R}}_m = \frac{1}{|\Omega_m|} \sum_{\mathbf{R}_i \in \Omega_m} \mathbf{R}_i, \quad m = 1, 2 \quad (2.36)$$

$$\mathbf{R}_i = \frac{\mathbf{X}_i \mathbf{X}_i^T}{\text{tr}(\mathbf{X}_i \mathbf{X}_i^T)} \quad (2.37)$$

式 (2.35) に正則化項を足した，

$$\hat{\mathbf{R}}_1 \mathbf{w} = \lambda(\alpha \hat{\mathbf{R}}_1 + \hat{\mathbf{R}}_2) \mathbf{w}, \quad 0 \leq \alpha \leq 1 \quad (2.38)$$

の最大一般化固有値に対応する一般化固有値ベクトルを $\hat{\mathbf{W}}_2$ とする．このとき， α は正則化パラメータである．

2.7.3 特徴抽出

2つの空間フィルタを組み合わせた特徴抽出方法について述べる．FC 最大フィルタはSN 比最大フィルタよりも識別に有効だと考えられるため，FC 最大フィルタを先に適用し， $\mathbf{d}_i, \mathbf{D}_i$ を以下のように求める．

$$\mathbf{d}_i = \hat{\mathbf{W}}_1^T \mathbf{X}_i, \quad \mathbf{D}_i = \mathbf{W}_1^T \mathbf{X}_i \quad (2.39)$$

次に \mathbf{D}_i を用いて，SN 比最大フィルタを適用する．

$$\mathbf{f}_i = \hat{\mathbf{W}}_2^T \mathbf{D}_i \quad (2.40)$$

そして， \mathbf{d}_i と \mathbf{f}_i を組み合わせて以下の特徴ベクトルを生成する．

$$\mathbf{Y}_i = [\mathbf{d}_i \ \mathbf{f}_i]^T \in \mathbb{R}^{(2 \times T)} \quad (2.41)$$

このようにして得られた特徴ベクトルは次善法 [26] にて FC と SN 比が最大となった特徴ベクトルとなる．




図 2.2: CLAFIC 法の例. ベクトル $P_c x$ の大きさを基準に x のクラスを判別する.




図 2.3: 投影距離法の例. 線分 \overline{XH} の長さを基準に x のクラスを判別する.

第3章 提案手法

この章では、本論文で提案する射影ノルムと投影距離を用いた空間フィルタとカーネル非線形 P300 部分空間を用いた空間フィルタについて述べる。本論文で提案する手法は全部で4つである。

3.1 従来手法の問題点

従来手法は、SN 比と FC を最大にするものであり、以下の問題点が挙げられる。まず一つは P300 は SN 比が元々低いことである [5][12]。そのため、SN 比を基準とした識別や特徴抽出は難しく、例え SN 比を基準とした空間フィルタを構成したとしてもあまり効果がないと考えられる。現に [12] によると、SN 比や識別率は SN 比最大フィルタよりも FC 最大フィルタを適用した方がよい結果を出している。

もう一つは SN 比と FC を最大化する空間フィルタを組み合わせていることである。[12] では組み合わせた方がよい結果が出たとしているが、組み合わせることにより特徴ベクトルの次元が固定されるため、識別するクラスが増えると分布の重なりが多くなり、正確な特徴抽出ができない可能性が考えられる。

そこで本論文では部分空間を基にした手法を提案し、従来手法との差別化を図る。この部分空間を基にした手法は従来法と比べ、扱うパラメータが多いためにより詳細な解析ができること、部分空間を用いているために安定した特徴抽出ができることが利点として挙げられる。

3.2 提案手法 1

提案手法 1 として、P300 部分空間への射影ノルムを基にした空間フィルタについて述べる。

3.2.1 P300 部分空間

P300 部分空間を求めるために PCA を用いる。自己相関行列 \mathbf{R} を以下のように定義する。

$$\mathbf{R} = \frac{1}{|\Omega_1|} \sum_{\mathbf{x}_{i,N_{ch}} \in \Omega_1} \mathbf{x}_{i,N_{ch}} \mathbf{x}_{i,N_{ch}}^T \quad (3.1)$$

これは Ω_1 に属する信号の時間方向に対する自己相関行列である。次に、 \mathbf{R} を固有値分解し、上位 r 個の固有値に対応する固有ベクトル $\mathbf{u}_1, \dots, \mathbf{u}_r$ を用いて、以下のように \mathbf{P} を求める。

$$\mathbf{P} = \sum_{n=1}^r \mathbf{u}_n \mathbf{u}_n^T \quad (3.2)$$

このとき、 \mathbf{P} は P300 部分空間への正射影である。

この P300 部分空間は P300 が含まれているパターンを r 次元の部分空間に射影したときに元のパターン分布との平均二乗誤差を最小にする空間である。

3.2.2 空間フィルタの設計

求める空間フィルタを ω としたとき, $\hat{\mathbf{X}}_i = \omega^T \mathbf{X}_i$ と置く. $\hat{\mathbf{X}}_i$ を $\mathbf{u}_1, \dots, \mathbf{u}_r$ で構成された P300 部分空間に射影したときの射影ノルムは,

$$\|P\hat{\mathbf{X}}_i^T\|^2 = \hat{\mathbf{X}}_i P P \hat{\mathbf{X}}_i^T = \omega^T \mathbf{X}_i P \mathbf{X}_i^T \omega \quad (3.3)$$

となる. この射影ノルムは $\hat{\mathbf{X}}_i$ に含まれる P300 の特徴の大きさを表す. そこで, P300 部分空間へ行列 $\hat{\mathbf{X}}_i$ を射影したときの射影ノルムの比を, P300 が含まれている信号と含まれていない信号との間で大きくする空間フィルタを設計する. この考えは次の評価関数によって定式化できる.

$$J(\omega) = \frac{\frac{1}{|\Omega_1|} \sum_{\mathbf{X}_i \in \Omega_1} \|P\hat{\mathbf{X}}_i^T\|^2}{\frac{1}{|\Omega_2|} \sum_{\mathbf{X}_i \in \Omega_2} \|P\hat{\mathbf{X}}_i^T\|^2} \quad (3.4)$$

最適な空間フィルタ ω は上記の評価関数を最大にする ω である. ここで, $\mathbf{A} = \frac{1}{|\Omega_1|} \sum_{\mathbf{X}_i \in \Omega_1} \mathbf{X}_i P \mathbf{X}_i^T$, $\mathbf{B} = \frac{1}{|\Omega_2|} \sum_{\mathbf{X}_i \in \Omega_2} \mathbf{X}_i P \mathbf{X}_i^T$ と置く. この問題の解は一般化固有値問題,

$$\mathbf{A}\omega = \lambda \mathbf{B}\omega \quad (3.5)$$

の最大一般化固有値に対応する一般化固有ベクトルとして求めることができる.

3.3 提案手法 2

提案手法 2 として, 投影距離を特徴抽出に用いた空間フィルタを提案する.

3.3.1 空間フィルタの設計

この手法では行列 \mathbf{X}_i の投影距離の比を, P300 が含まれている信号と含まれていない信号との間で大きくする空間フィルタを設計する. この考えは次の評価関数によって定式化できる.

$$J(\omega) = \frac{\frac{1}{|\Omega_2|} \sum_{\mathbf{X}_i \in \Omega_2} \omega^T \mathbf{D}(\mathbf{X}_i) \omega}{\frac{1}{|\Omega_1|} \sum_{\mathbf{X}_i \in \Omega_1} \omega^T \mathbf{D}(\mathbf{X}_i) \omega} \quad (3.6)$$

ここで, $\mathbf{D}(\mathbf{X}_i)$ は空間投影距離を表しており, 以下のように定義される.

$$\begin{aligned} \mathbf{D}(\mathbf{X}_i) = & (\mathbf{X}_i - \bar{\mathbf{X}}_1)(\mathbf{X}_i - \bar{\mathbf{X}}_1)^T \\ & - \sum_{d=1}^k ((\mathbf{X}_i - \bar{\mathbf{X}}_1)\Phi_d)((\mathbf{X}_i - \bar{\mathbf{X}}_1)\Phi_d)^T \end{aligned} \quad (3.7)$$

ここで Φ_d はクラス 1 の共分散行列の第 d 固有ベクトルを表している. クラス 1 の共分散行列 \mathbf{C} は以下のように表される.

$$\mathbf{C} = \frac{1}{|\Omega_1|} \sum_{\mathbf{X}_i \in \Omega_1} (\mathbf{X}_i - \bar{\mathbf{X}}_1)(\mathbf{X}_i - \bar{\mathbf{X}}_1)^T \quad (3.8)$$

最適な空間フィルタは式 (3.6) の評価関数を最大にする ω である.

3.4 線形部分空間を用いた空間フィルタの問題点

前節で述べた空間フィルタは線形部分空間を用いたが、これには2つの問題点がある。一つは観測信号の分布が非線形な軸に沿って広がる場合、線形主成分分析によって定まる主成分分析は意味を成さず、それで得られる部分空間は必ずしもその観測信号を特徴づけるものであるとは限らない。

もう一つはクラス数に対して特徴空間の次元が小さい場合、分布の重なりが増え易いため、一般的に特徴抽出が難しい。そのため、クラス数が多い課題に対しては線形部分空間を用いた空間フィルタを適用する場合は注意が必要である。

頭皮にはP300を含め、様々な要因で引き起こされた様々な成分を持つEEGが脳の動作ごとに発生しており、個々の電極はそれらのEEGの集まりを観測する。そのため、頭皮から観測されるEEGは線形判別が難しい複雑な分布を持つと考えられる。また、EEGに含まれる信号の周波数は高くても30Hz程度であるため、サンプリング周波数は一般的に低く、クラス数に対して電極ごとの特徴空間の次元が小さい傾向にある。以上の理由から線形部分空間を用いた部分空間では特徴抽出に不十分な部分があると考えられる。

そこで、本研究ではカーネル関数を介して、カーネル非線形P300部分空間を用いた空間フィルタを提案する。この手法は前田らが提案したカーネル非線形部分空間法 [21] を基にしている。カーネル非線形部分空間法は、部分空間を構成する際に分布の非線形性を吸収することが可能であり、さらにカーネル関数を介した非線形変換は高次元への変換であるため、分布の重なりを防ぐことができると考えられる。

3.5 カーネル関数

本研究では、カーネル関数 k として以下に表されるような関数を用いる。任意の \hat{d} 次元パターンベクトル \mathbf{x}, \mathbf{y} に対して、

$$k(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2p^2}\right) \quad (3.9)$$

とする。上記のカーネル関数は分散 p^2 の広がりを持つ Gaussian Radial Basis Function (RBF) に相当する。RBF カーネルは一番よく使われるカーネル関数であり、具体的な $\mathbb{R}^{\hat{d}}$ から \mathcal{H} への写像 $\phi(\mathbf{x})$ が存在するための条件であるマーサーの条件を満たす [18]。マーサーの条件とは以下の式を満たすことである。

$$k(\mathbf{x}, \mathbf{y}) = \phi(\mathbf{x})^* \phi(\mathbf{y}) = \sum_{i=1}^{d_\phi} \phi_i(\mathbf{x}) \phi_i(\mathbf{y}) \quad (3.10)$$

また、RBF カーネルの場合、 d_ϕ の大きさは ∞ である。

3.6 提案手法3

提案手法3として、カーネルP300部分空間を用いた空間フィルタを提案する。

3.6.1 カーネル非線形 P300 部分空間を用いた非線形部分空間の構成

カーネル非線形 P300 部分空間の構成にはカーネル非線形部分空間法 [21] で提案されている手法を用いる。カーネル関数を利用してクラス非線形部分空間を構成するためには Schököpf らによって提案されたカーネル非線形主成分分析を用いる [22]。この手法ではカーネル関数だけが与えられ、非線形変換 ϕ が明確に定義されないため、一般に非線形空間での分布の主成分を求めることはできないが、非線形変換後のパターンベクトルと非線形部分空間を張るベクトルとの内積は特異値分解を用いることで算出することができる。以下ではその方法について述べる。

任意の \hat{d} 次元パターン $\mathbf{x}_1, \dots, \mathbf{x}_n$ および非線形変換 $\phi(\mathbb{R}^{\hat{d}} \rightarrow \mathcal{H})$ を用いて、行列 \mathbf{X} と作用素 \mathbf{X}_ϕ を

$$\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_n] \quad (3.11)$$

$$\mathbf{X}_\phi = [\phi(\mathbf{x}_1), \dots, \phi(\mathbf{x}_n)] \quad (3.12)$$

と定義する。同様にして行列 \mathbf{Y}, \mathbf{Z} と作用素 $\mathbf{Y}_\phi, \mathbf{Z}_\phi$ を

$$\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_m] \quad (3.13)$$

$$\mathbf{Y}_\phi = [\phi(\mathbf{y}_1), \dots, \phi(\mathbf{y}_m)] \quad (3.14)$$

$$\mathbf{Z} = [\mathbf{z}_1, \dots, \mathbf{z}_l] \quad (3.15)$$

$$\mathbf{Z}_\phi = [\phi(\mathbf{z}_1), \dots, \phi(\mathbf{z}_l)] \quad (3.16)$$

と定義する。また、 $\mathbf{K}(\mathbf{Y}, \mathbf{Z})$ を

$$\mathbf{K}(\mathbf{Y}, \mathbf{Z}) = \mathbf{Y}_\phi^* \mathbf{Z}_\phi \quad (3.17)$$

と定義する。

ここで作用素 \mathbf{X}_ϕ に対して特異値分解を行う。 $\mathbf{X}_\phi^* \mathbf{X}_\phi$ の固有値を λ_i ($\lambda_1 \geq \dots \geq \lambda_n$) とおくと、正の固有値は $\text{rank}(\mathbf{X}_\phi) = r$ 個存在し、 $\mathbf{X}_\phi \mathbf{X}_\phi^*$ の正の固有値と一致する。固有値 λ_i に対応する $\mathbf{X}_\phi^* \mathbf{X}_\phi$, $\mathbf{X}_\phi \mathbf{X}_\phi^*$ の正規直交固有ベクトルをそれぞれ、 $\mathbf{u}_i, \mathbf{v}_i$ とし、行列 \mathbf{U} と有界線形作用素 $\mathbf{V}, \mathbf{\Lambda}$ を

$$\mathbf{U} = [\mathbf{u}_1, \dots, \mathbf{u}_r] \in \mathbb{R}^{n \times r} \quad (3.18)$$

$$\mathbf{V} = [\mathbf{v}_1, \dots, \mathbf{v}_r], \quad \mathbf{v}_i \in \mathcal{H} \quad (3.19)$$

$$\mathbf{\Lambda} = \begin{bmatrix} \sqrt{\lambda_1} & & 0 \\ & \ddots & \\ 0 & & \sqrt{\lambda_r} \end{bmatrix} \quad (3.20)$$

とおけば、特異値分解より、

$$\mathbf{X}_\phi = \mathbf{V} \mathbf{\Lambda} \mathbf{U}^T \quad (3.21)$$

となる。 $\mathbf{X}_\phi \mathbf{X}_\phi^*$ はパターン集合 $(\phi(\mathbf{x}_1), \dots, \phi(\mathbf{x}_n))$ の自己相関行列の n 倍であるから、 \mathbf{v}_i はパターン集合の i 番目の主成分方向を指す。特異値分解の特性から

$$\mathbf{v}_i = \frac{1}{\sqrt{\lambda_i}} \mathbf{X}_\phi \mathbf{u}_i \quad (3.22)$$

が成り立つので、 \mathbf{Z} の j 番目のベクトルを \mathbf{z}_j とすると、 $\phi(\mathbf{z}_j)$ の \mathbf{v}_i への射影は

$$\mathbf{v}_i^* \phi(\mathbf{z}_j) = \frac{1}{\sqrt{\lambda_i}} \mathbf{u}_i^T \mathbf{X}_\phi^* \phi(\mathbf{z}_j) \quad (3.23)$$

$$= \frac{1}{\sqrt{\lambda_i}} \mathbf{u}_i^T \mathbf{K}(\mathbf{X}, \mathbf{z}_j) \quad (3.24)$$

となる。そのため、 \mathbf{Z}_ϕ の \mathbf{V} への射影は

$$\mathbf{V}^* \mathbf{Z}_\phi = \mathbf{\Lambda}^{-1} \mathbf{U}^T \mathbf{K}(\mathbf{X}, \mathbf{Z}) \quad (3.25)$$

と表すことができる。一方、 $\mathbf{\Lambda}$ と \mathbf{U} は $\mathbf{X}_\phi^* \mathbf{X}_\phi$ 、すなわち $\mathbf{K}(\mathbf{X}, \mathbf{X})$ の固有値と固有ベクトルとして求まる。

以上から、任意のパターン \mathbf{z} に対し、非線形部分空間の第 i 主成分方向 \mathbf{v}_i への $\phi(\mathbf{z}_j)$ の射影はカーネル関数が与えられれば求めることができるため、 ϕ の具体的な形を知る必要はないことがわかる。

3.6.2 空間フィルタの設計

ここで提案する空間フィルタはカーネル非線形部分空間への射影ノルムの比を P300 が含まれている信号と含まれていない信号との間で大きくするものである。最適な空間フィルタは下記の評価関数を最大にする ω である。

$$J(\omega) = \frac{\frac{1}{|\Omega_1|} \sum_{\mathbf{x}_i \in \Omega_1} \omega^T \mathbf{K}_i^T \mathbf{K}_i \omega}{\frac{1}{|\Omega_2|} \sum_{\mathbf{x}_i \in \Omega_2} \omega^T \mathbf{K}_i^T \mathbf{K}_i \omega} \quad (3.26)$$

このとき、 $\mathbf{K}_i = \mathbf{\Lambda}_d^{-1} \mathbf{U}_d^T \mathbf{K}(\mathbf{H}, \mathbf{X}_i^T)$ である。また、P300 の学習用行列 \mathbf{H} を、以下のように表す。

$$\mathbf{H} = [\mathbf{X}_{O_1(1)}^T, \dots, \mathbf{X}_{O_1(|\Omega_1|)}^T] \in \mathbb{R}^{T \times N|\Omega_1|} \quad (3.27)$$

ここで、 $O_1(j)$ はクラス 1 に属する j 番目の信号を表す。さらに、 $\mathbf{\Lambda}_d$ と \mathbf{U}_d はそれぞれ、 $\mathbf{K}(\mathbf{H}, \mathbf{H})$ の固有値の平方根の対角行列、固有ベクトルであり、 d は部分空間の次元を表している。

3.7 提案手法 4

提案手法 4 ではカーネル投影距離を用いた空間フィルタを提案する。

3.7.1 カーネル共分散行列

$\phi(\mathbf{x}_i)$ の平均ベクトルを ϕ_M とおくと

$$\phi_M = \frac{1}{n} \sum_{j=1}^n \phi(\mathbf{x}_j) = \frac{1}{n} \mathbf{X}_\phi \mathbf{1}_n \quad (3.28)$$

となる．ここで， $\mathbf{1}_n$ は全要素に 1 を持つ n 次元ベクトルである．次に $\mathbf{X}_{\bar{\phi}}$ を

$$\begin{aligned}\mathbf{X}_{\bar{\phi}} &= \mathbf{X}_{\phi} - \phi_M \mathbf{1}_n^T \\ &= \mathbf{X}_{\phi} - \frac{1}{n} \mathbf{X}_{\phi} \mathbf{1}_{nn}\end{aligned}\quad (3.29)$$

とする．ここで $\mathbf{1}_{nn}$ は全要素に 1 をもつ $n \times n$ 行列である．同様に，

$$\begin{aligned}\mathbf{Y}_{\bar{\phi}} &= \mathbf{Y}_{\phi} - \phi_M \mathbf{1}_n^T \\ &= \mathbf{Y}_{\phi} - \frac{1}{n} \mathbf{X}_{\phi} \mathbf{1}_{nm}\end{aligned}\quad (3.30)$$

$$\begin{aligned}\mathbf{Z}_{\bar{\phi}} &= \mathbf{Z}_{\phi} - \phi_M \mathbf{1}_n^T \\ &= \mathbf{Z}_{\phi} - \frac{1}{n} \mathbf{X}_{\phi} \mathbf{1}_{nl}\end{aligned}\quad (3.31)$$

と定義する．そして， $\mathbf{G}_X(\mathbf{Y}, \mathbf{Z})$ を

$$\begin{aligned}\mathbf{G}_X(\mathbf{Y}, \mathbf{Z}) &= \mathbf{Y}_{\bar{\phi}}^* \mathbf{Z}_{\bar{\phi}} = (\mathbf{Y}_{\phi} - \frac{1}{n} \mathbf{X}_{\phi} \mathbf{1}_{nm})^* (\mathbf{Z}_{\phi} - \frac{1}{n} \mathbf{X}_{\phi} \mathbf{1}_{nl}) \\ &= \mathbf{K}(\mathbf{Y}, \mathbf{Z}) - \frac{1}{n} \mathbf{K}(\mathbf{Y}, \mathbf{X}) \mathbf{1}_{nl} - \frac{1}{n} \mathbf{1}_{mn} \mathbf{K}(\mathbf{X}, \mathbf{Z}) + \frac{1}{n^2} \mathbf{1}_{mn} \mathbf{K}(\mathbf{X}, \mathbf{X}) \mathbf{1}_{nl}\end{aligned}$$

と定義する．このとき， $\mathbf{G}_Z(\mathbf{Z}, \mathbf{Z})$ とすると，これは \mathbf{Z} に対するカーネル共分散行列となる．

3.7.2 空間フィルタの設計

ここで提案する空間フィルタはカーネル投影距離の比を P300 が含まれている信号と含まれていない信号との間で大きくするものである．最適な空間フィルタは下記の評価関数を最大にする ω である．

$$J(\omega) = \frac{\frac{1}{|\Omega_2|} \sum_{\hat{\mathbf{X}}_i \in \Omega_2} \omega^T \mathbf{D}_{\phi}(\mathbf{X}_i) \omega}{\frac{1}{|\Omega_1|} \sum_{\hat{\mathbf{X}}_i \in \Omega_1} \omega^T \mathbf{D}_{\phi}(\mathbf{X}_i) \omega}\quad (3.32)$$

ここで， $\mathbf{D}_{\phi}(\mathbf{X}_i)$ はカーネル投影距離であり， $\hat{\Lambda}_d$ と $\hat{\mathbf{U}}_d$ をそれぞれ， $\mathbf{G}_H(\mathbf{H}, \mathbf{H})$ の固有値の平方根の対角行列とそれに対応する固有ベクトルとすると，以下のように表される．

$$\mathbf{D}_{\phi}(\mathbf{X}_i) = \mathbf{G}_H(\mathbf{X}_i^T, \mathbf{X}_i^T) - \mathcal{D}_i \mathcal{D}_i^T\quad (3.33)$$

ここで， $\mathcal{D}_i = \hat{\Lambda}_d^{-1} \hat{\mathbf{U}}_d^T \mathbf{G}_H(\mathbf{H}, \mathbf{X}_i^T)$ である．

3.8 空間フィルタによる特徴抽出

提案手法 1, 2, 3, 4 に対する最適な空間フィルタは，それぞれの一般化固有値問題に対する最大固有ベクトルとして与えられるが，最大固有ベクトル以外の固有ベクトルも特徴抽出に有効であると考えられる．本研究では式 (3.5) によって得られる N 個の固有ベクトルを固有値の大きい順に並べ $\hat{\omega}^{(1)}, \dots, \hat{\omega}^{(k)}, \dots, \hat{\omega}^{(N)}$ とし，上位 K 個の固有ベクトルを合わせた $\mathbf{W} \in \mathbb{R}^{N \times K}$

を未知データの特徴抽出に用いて，提案手法 1 と 3 は

$$\mathbf{V}_i = \begin{bmatrix} v_{i,1}(0) & \cdots & v_{i,1}(T-1) \\ \vdots & \ddots & \vdots \\ v_{i,K}(0) & \cdots & v_{i,K}(T-1) \end{bmatrix} = \mathbf{W}^T \mathbf{X}_i \quad (3.34)$$

$$\mathbf{v}_{i,k} = [v_{i,k}(0), \dots, v_{i,k}(T-1)]^T, \quad k = 1, \dots, K \quad (3.35)$$

とし，提案手法 2 と 4 は

$$\hat{\mathbf{V}}_i = \begin{bmatrix} \hat{v}_{i,1}(0) & \cdots & \hat{v}_{i,1}(T-1) \\ \vdots & \ddots & \vdots \\ \hat{v}_{i,K}(0) & \cdots & \hat{v}_{i,K}(T-1) \end{bmatrix} = \mathbf{W}^T (\mathbf{X}_i - \bar{\mathbf{X}}_1) \quad (3.36)$$

$$\hat{\mathbf{v}}_{i,k} = [\hat{v}_{i,k}(0), \dots, \hat{v}_{i,k}(T-1)]^T, \quad k = 1, \dots, K \quad (3.37)$$

として，未知データの識別を行った．

第4章 データセット

評価実験のために、オドボール課題を用いた2つのP300-based BCIのデータセットを用いた。

4.1 聴性 BCI

聴覚刺激に肉声を用いた聴性 BCI のデータセットを用いた。このデータセットは、被験者に「上」、「下」、「左」、「右」の肉声を音声刺激として呈示し、そのときの脳波を調べることによって被験者がどの音声刺激を意識して聞いていたか（注目刺激であったか）を推定するためのものである。

音声呈示されるスピーカーの数は4つであり、被験者を中心に前後左右に配置した。スピーカーが刺激を呈示する順番と刺激の種類はランダムである。このとき、同じスピーカーから連続して刺激が呈示されず、さらに同じ刺激も連続して呈示されない。この音声呈示方法の例を図4.2に示す。1つの音声刺激の長さは0.5秒で、音声刺激が呈示されてから0.25秒後に次の音声刺激が呈示される。各刺激は1試行につき5回、計20回呈示される。被験者8人分、被験者1人につき50試行分データを使用した。被験者は22～24歳の男性である。サンプリング周波数は512Hzであり、データ採取時に遮断周波数0.5Hzから100Hzのバンドパスフィルタがかけられている。電極の配置を図4.3に示す。P300は他の部位に比べて頭頂部付近でより強く観測される傾向があるため、Czを中心に配置されている[5][7]。グラウンドはAFz、リファレンスはA2である。

4.2 P300 speller

2つ目のデータセットとして、BCI Competition III dataset II P300 Speller paradigm[8][9]を用いた。このデータセットは、図4.4に示す6×6の文字行列のいずれかの行、または列がランダムに光り、そのときの脳波を調べることによって、被験者が36文字の中からどの文字を意識して見ていたか（注目刺激であったか）を推定するものである。

この実験ではいずれかの行もしくは列が100ms光った後、75ms何も光らない状態になる。その後、また別の行もしくは列が光る。従って、刺激呈示間隔は175msである。精度向上のため、文字行列の行と列が1度ずつランダムに光るのを1シーケンスとする。1試行につき15シーケンス繰り返す。このデータセットには2名分の被験者A、B共に185試行分のEEGが用意されている。このデータセットのサンプリング周波数は240Hzであり、データ採取時に遮断周波数0.1Hzから60Hzのバンドパスフィルタがかけられている。

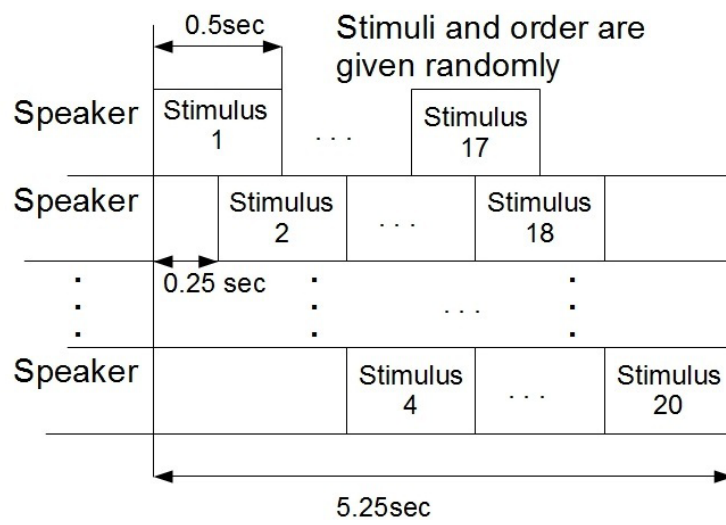


図 4.1: 音声刺激呈示方法.

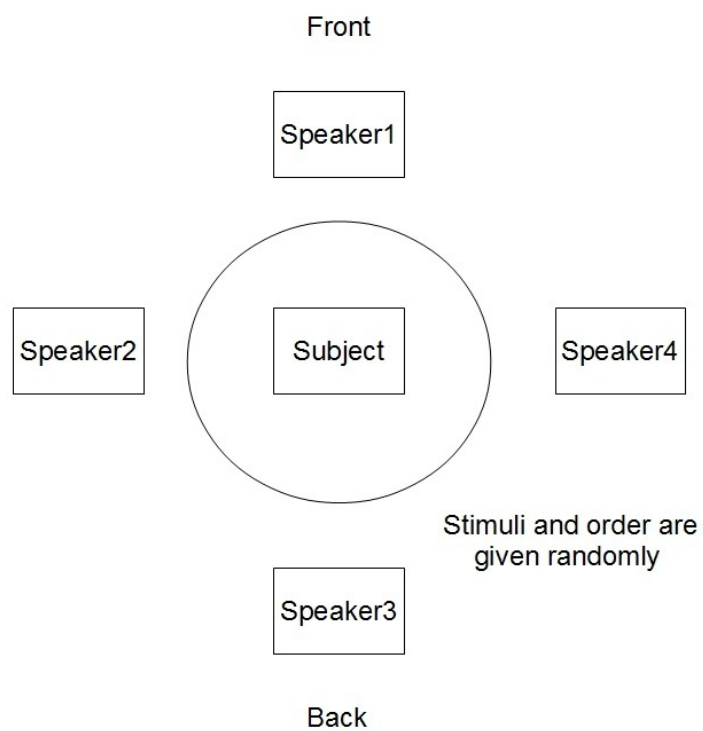


図 4.2: スピーカ配置図.




図 4.3: 電極配置図: 拡張国際 10-20 法に準拠している.



図 4.4: P300 speller の刺激の呈示例.

第5章 実験方法

本実験では、提案手法と空間フィルタを用いない手法である従来手法と [12] の C-FMS beamformer を脳波の識別率を比較する．識別率の算出には5分割交差検定を用いた．各被験者に対して50試行分の脳波を用いて交差検定を行った．解析には次元削減と特徴抽出にPCAを，識別器にはLDA (Linear discriminant Analysis) を用いた．識別までの手順を図5.1に示す．また，分散分析と多重比較検定を用いて提案手法と従来手法の実験結果に有意差があるかどうかを確認した．有意水準は5%で検定した．

5.1 前処理

前処理として2つのデータセットに対してバンドパスフィルタリングとダウンサンプリング，加算平均処理を行った．

聴性BCIのデータセットに対しては0.5Hzから10Hzの遮断周波数を持つバンドパスフィルタを適用し，32Hzにダウンサンプリングした．加算平均処理は1試行の各刺激ごとに行った．また，チャンネルごとに信号のノルムが1になるように正規化を行った

P300 speller のデータセットに対しては，0.5Hz から 10Hz の遮断周波数を持つバンドパスフィルタを適用し，30Hzにダウンサンプリングした．解析に用いる電極は聴性BCIと同じものを選んだ．加算平均処理は1試行の各刺激ごとに行った．

5.2 特徴ベクトル

提案手法1と3の特徴ベクトルは式(5.1)のようにして生成した．従来手法の場合， $\mathbf{v}_{i,k}$ の代わりに $\mathbf{x}_{i,N_{ch}}$ を用い，提案手法2と4の場合， $\mathbf{v}_{i,k}$ の代わりに $\hat{\mathbf{v}}_{i,k}$ を用いる．

$$\mathbf{Z}_i = \left[\mathbf{v}_{i,1}^T, \mathbf{v}_{i,2}^T, \dots, \mathbf{v}_{i,K}^T \right]^T \quad (5.1)$$

従来手法は $\mathbf{x}_{i,N_{ch}}$ を N 個連結させた $(T \times N)$ 次元のベクトルを，提案手法は空間フィルタ適用後のベクトルを K 個連結させた $(T \times K)$ 次元のベクトルを特徴ベクトルとした．従来手法2は式(2.41)により特徴ベクトルを生成した．

5.3 PCAによる次元削減と特徴抽出

特徴ベクトルを用いて，自己相関行列 \mathbf{R}' を求める．

$$\mathbf{R}' = \frac{1}{|\Omega_1| + |\Omega_2|} \sum_i \mathbf{Z}_i \mathbf{Z}_i^T \quad (5.2)$$

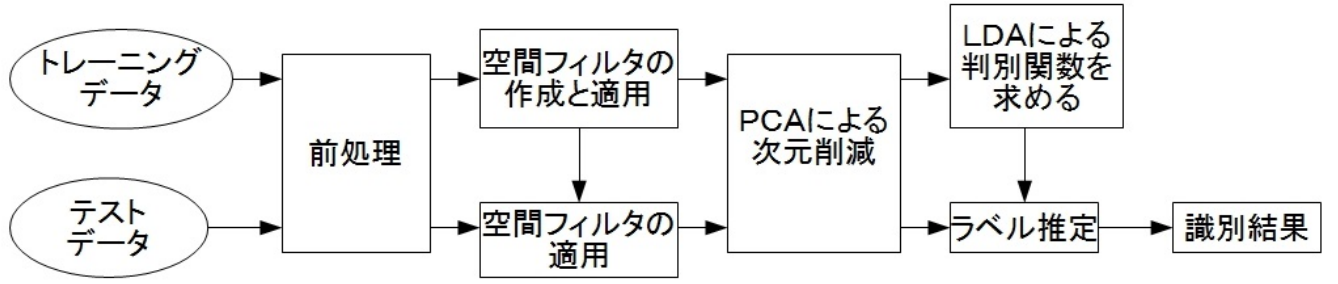


図 5.1: 実験手順の概要.

とする. 次に, \mathbf{R}' の固有値 $(\lambda_1, \dots, \lambda_{(KT)})$ のそれぞれに対応する固有ベクトルを $(\mathbf{u}_1, \dots, \mathbf{u}_{(KT)})$ とする. ここで, $(\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{(KT)})$ である. そして, PCA の変換行列を

$$\mathbf{U} = [\mathbf{u}_1, \dots, \mathbf{u}_{r_2}] \in \mathbb{R}^{(KT) \times r_2}, \quad r_2 \leq \min(KT, |\Omega_1| + |\Omega_2|) \quad (5.3)$$

として求め, すべての \mathbf{Z}_i に対して $\mathbf{Z}'_i = \mathbf{U}^T \mathbf{Z}_i$ として, \mathbf{U} の列ベクトルを基底とする新しい座標系に展開した.

5.4 LDA による識別

未知の信号に対して特徴ベクトルを求め, $\mathbf{Z}'_{c'}$ とする. ここで, c' はコマンドに対するインデックスである. 例えば, 聴性 BCI では $c' = \{1, 2, 3, 4\} = \{\text{「上」}, \text{「下」}, \text{「左」}, \text{「右」}\}$ であり, P300 speller では $c' = \{1, \dots, 36\} = \{\text{「A」}, \dots, \text{「_」}\}$ である. LDA を用いて求めた $\boldsymbol{\omega}'$ を用いて, 未知の信号のラベル \hat{c} は以下のようにして推定した.

$$\hat{c} = \arg \max_{c'} \boldsymbol{\omega}'^T \mathbf{Z}'_{c'} \quad (5.4)$$

5.5 評価方法

手法ごとに交差検定を用いて識別し, 識別結果を分散分析と多重比較検定を用いて事後比較した.

5.5.1 交差検定

識別率の評価方法には交差検定を用いた. 交差検定は, 識別に用いるデータを分割し, 複数回識別実験を繰り返すことで学習データとテストデータの偏りを減らし, 識別率の誤差を減らすための統計処理手法である. n -分割交差検定はまず, m 個ある特徴ベクトルを n 個の特徴ベクトル群にランダムに分割し, $n - 1$ 個の特徴ベクトル群を学習データ, 残り 1 個の特徴ベクトル群をテストデータとして識別する. これを n 回繰り返し, それぞれの結果の平均をとることで識別率を算出する. このとき, 分割されたすべてのベクトル群が n 回の中で 1 度はテストデータになるようにする. 本論文では 50 試行分のデータについて, 各パラメータごとに 5-分割交差検定を用いて識別率を算出した.

5.5.2 分散分析

識別結果の平均値に違いがあるかどうかを調べるために分散分析を行った。分散分析とは得られたデータが母平均の等しいデータ群から抽出される可能性が高いかどうかを検討するために行われる検定である [23]。本実験では分散分析として、対応ありの一元配置分散分析を行った。ここで、一元配置分散分析とはある 1 つの条件の違いによって母平均が異なるかどうかを検定することであり、対応ありとは同じ被験者が複数の条件を経験するようなデータに対して、その関係性を考慮して検定を行うことである [23]。一般に対応のあるデータで、対応のあることを考慮せずに検定を行うと検出力が低下して有意な結果が得られにくくなることが知られている [23]。

帰無仮説を「6 群の母平均は等しい」とし、空間フィルタの手法の違いによって 6 群の母平均が異なるかどうかを検定した。有意水準 5% で検定を行った。また、聴性 BCI と P300 speller の被験者を合わせて検定した。

5.5.3 多重比較検定

それぞれの識別結果の有意差を調べるため、多重比較検定を行った。多重比較検定は主に 3 群以上の平均値を比較するための統計的方法であり、同じデータに複数回検定を適用することで発生する、帰無仮説が真のときにこれを棄却してしまう誤りである第 1 種の誤りを犯す確率が大きくなってしまいう問題を回避するために用いられる検定である [23]。この問題は一般的に検定の多重性の問題と呼ばれ、第 1 種の誤りを犯す確率は有意水準、または危険率と呼ばれる。

例えば、独立する三群 A, B, C の平均 μ_A, μ_B, μ_C について、検定する帰無仮説が $\mu_A = \mu_B = \mu_C$ であり、そのために $\mu_A = \mu_B, \mu_A = \mu_C, \mu_B = \mu_C$ をそれぞれ有意水準 α で検定するとする。このとき、この 3 つに分けた検定のうち少なくとも 1 つで第 1 種の誤りを犯している確率は、それぞれが独立で $\alpha > 0$ ならば

$$1 - (1 - \alpha)^3 > \alpha \quad (5.5)$$

となる。これはもともとの仮説について有意水準 α で検定を行うことができなかったことを表している。多重比較検定はこの検定の多重性の問題について、もともとの仮説について第 1 種の誤りを犯す確率が α を超えないように検定を行う。また、多重比較検定では帰無仮説の p 値が有意水準以上となった場合、帰無仮説を採択するのではなく、判定は保留となる。

多重比較検定の中にはパラメトリック検定とノンパラメトリック検定が存在する。パラメトリック検定とはデータの分布がある特定の分布に従うことがわかっているデータに対して、または特定の分布に従うと仮定して行う検定法である。一方、ノンパラメトリック検定とはデータに対する仮定を一切行わない検定法である。本来、パラメトリック検定を行うことができるデータに対してノンパラメトリック検定を行うと、帰無仮説を棄却できるのにも関わらず帰無仮説を採用してしまう確率である第 2 種の誤り β が大きく上昇し、検定の検出力 $(1 - \beta)$ が低下することが知られている [31]。

パラメトリック多重比較検定の中でもっともよく使われているのは Honestly Significant Difference (HSD) 基準を用いた Tukey 法である [23]。この手法は分布調整型多重比較法と呼ばれる手法で、全ての 2 群同士を同時に比較（対比較）するパラメトリック検定であり、多重性が

考慮された分布であるスチューデント化された範囲分布 (q 分布) に基づく検定を行う [33]. しかし, Tukey の HSD 法は本実験で扱うデータのような対応のあるデータに対して用いることは問題があるという指摘がされている [33].

そのため, 対応のあるデータに対して行うパラメトリック多重検定には有意水準調整型のものを用いることが挙げられる. これは3つ以上の群に対してもととの仮説についての第1種の誤りを犯す確率が有意水準を超えないように, それぞれの群同士に対する検定の有意水準をコントロールする手法である [33]. 本実験では有意水準調整型のパラメトリック多重検定の中でも Holm 法を用いる. Holm 法は一律に厳しい有意水準を全ての群の比較ペアに適用する Bonferroni 法に代表されるような, 比較する群の数が多いと有意差が出にくいとされる保守的な有意水準調整型の短所を改善させた手法であり, ペア l ごとに適用される有意水準 $\alpha'(l)$ が異なる [33]. Holm 法では $\alpha'(l)$ は

$$\alpha'(l) = \frac{\alpha}{L - B(l) + 1} \quad (1 \leq B(l) \leq L) \quad (5.6)$$

として定義される. ここで L は比較する総ペア数であり, $B(l)$ は全てのペアの統計検定量に対応する対応する確率 (p 値) を確率の小さい順に並び替えた時のペア l の順番である. Holm 法は Bonferroni 法と違い, p 値の小さいペアから順に検定を行い, 一度でも帰無仮説が有意水準を超えると, それ以降の順のペアの判定は p 値に関わらず全て保留になる.

本実験では得られたデータは正規分布に従うと仮定し, 多重検定として Holm 法を用いる. 帰無仮説は「二群間の平均値に差は無い」とし, 有意水準 5% ($\alpha = 0.05$) で検定をした. また, 聴性 BCI と P300 speller の被験者を合わせて検定した.

5.6 t 検定

「二群間の平均値に差は無い」という帰無仮説を検定するには t 検定を用いる. t 検定とは標本抽出を行って母数の推測を行う統計的仮説検定のひとつで, 母集団の分散 σ^2 がわからないとき, データから求められる不偏分散の正の平方根である $\hat{\sigma}$ を用いて計算される統計量が帰無仮説のもとで, t 分布に従う性質を用いて検定を行うものである [23]. t 分布とは統計学でよく利用される確率分布の一つで, 形状は正規分布に似ていて, 左右対称で山型の分布である [23]. t 分布は自由度という数値によりその形状が決まり, 自由度の値が低いほど, 山のてっぺんが低く, 両裾が高い形状になる. 本実験では, 対応ありの t 検定を行った.

5.7 パラメータ

パラメータは, 従来手法 1 では解析に用いる PCA のランク r_2 の 1 つ, 従来手法 2 では正規化に用いるパラメータ α, θ と r_2 の 3 つである. 提案手法 1, 2 では P300 部分空間を形成するときの PCA のランク r , 空間フィルタに用いる固有ベクトルの個数 K , r_2 の 3 つ, 提案手法 3 と 4 ではさらにそれらにカーネル関数のパラメータ p を加えた 4 つである. これらのパラメータの最適値は交差検定を用いて求めた. 交差検定に用いたパラメータは具体的には $\alpha = \theta = [0, 0.1, \dots, 1]$, $K = [1, 2, \dots, N]$, p に関しては聴性 BCI のとき, $p = [0.1, 0.2, \dots, 1]$,

P300sepeller のとき, $p = [1, 2, \dots, 20]$, r は累積寄与率 0.90 までの固有値の数, r_2 は累積寄与率 0.99 までの固有値の数である.

累積寄与率とは固有値が全体の情報量に対してどのくらいの情報量を保有しているかを表しており, 以下の式で表される.

$$l = \frac{\sum_{i=1}^r \lambda_i}{\sum_i \lambda_i} \quad (5.7)$$

このとき, l は累積寄与率を, λ_i は第 i 固有値を, r は固有値の数を表している.

第6章 実験結果

この章では実験によって得られた結果を示す.

6.1 識別率

表 6.1 に識別率の結果を示す. この結果は 5 分割交差検定を 50 回行った平均である.

6.2 最適パラメータ

表 6.2 に各手法の交差検定で得られた最適なパラメータを示す. この結果は 5 分割交差検定を 50 回行った平均である.

6.3 検定

分散分析の p 値は 2.57×10^{-12} であった. 表 6.3 に多重比較検定の結果を示す. この結果は検定の結果に Holm 法による補正をした結果であり, 結果に示してある p 値が有意水準 0.05 を下回っていた場合は帰無仮説を棄却と判定し, 上回っていた場合は判定を保留とする.

6.4 頭皮上マッピング

各空間フィルタの最適なパラメーターで算出した第一固有ベクトルを頭皮上分布としてマッピングしたものを図 6.1 から 6.10 に示す. この図は等高線を表しており, 色が赤に近ければ近いほどフィルタの係数が大きく, 青に近ければ近いほど小さいことを表している. 空間フィルタの係数の絶対値は, 判別に重要な電極に対して大きくなるため, この頭皮上分布はどの電極が, もしくは頭のどの部分が判別に重要な特徴をより強く持っているかを表しているといえる.

表 6.1: 識別結果 (% \pm 標準偏差)

被験者	従来手法 1	従来手法 2	提案手法 1	提案手法 2	提案手法 3	提案手法 4
1	65.80 \pm 4.025	69.16 \pm 3.639	80.20 \pm 2.499	75.84 \pm 2.419	82.60 \pm 2.222	77.40 \pm 2.778
2	74.76 \pm 3.426	75.68 \pm 2.691	79.28 \pm 3.150	78.32 \pm 3.602	80.56 \pm 2.459	78.64 \pm 2.753
3	88.68 \pm 1.789	91.08 \pm 2.498	90.88 \pm 1.945	88.08 \pm 1.759	95.12 \pm 1.350	92.60 \pm 1.628
4	62.88 \pm 3.360	61.52 \pm 3.300	66.08 \pm 2.884	64.92 \pm 2.747	73.36 \pm 2.724	70.80 \pm 2.884
5	81.06 \pm 2.680	82.48 \pm 2.121	88.04 \pm 2.231	91.36 \pm 1.638	93.64 \pm 2.077	86.48 \pm 2.082
6	74.68 \pm 1.921	77.16 \pm 1.983	80.28 \pm 2.286	76.20 \pm 2.147	85.96 \pm 1.916	78.80 \pm 2.063
7	80.48 \pm 2.042	82.84 \pm 2.142	88.92 \pm 1.724	88.80 \pm 1.807	91.72 \pm 1.896	88.76 \pm 1.451
8	90.24 \pm 2.200	94.60 \pm 1.578	97.12 \pm 1.230	97.24 \pm 1.135	96.92 \pm 1.158	95.84 \pm 0.9765
A	68.84 \pm 2.957	68.40 \pm 3.023	74.20 \pm 1.726	69.64 \pm 2.640	75.76 \pm 2.006	69.20 \pm 2.355
B	76.52 \pm 2.705	81.60 \pm 1.895	85.84 \pm 1.658	82.24 \pm 2.162	86.42 \pm 2.06	84.36 \pm 1.605
平均	76.40	78.45	83.08	81.26	87.21	82.28

表 6.2: 最適パラメータ

被験者	従来手法 1 (r_2)	従来手法 2 (α, θ, r_2)	提案手法 1 (r, k, r_2)	提案手法 2 (r, k, r_2)	提案手法 3 (r, k, r_2, p)	提案手法 4 (r, k, r_2, p)
1	47.56	(0.302, 0.352, 17.5)	(6.14, 13.5, 43.3)	(5.54, 13.2, 33.4)	(22.0, 13.4, 48.4, 0.522)	(9.38, 13.5, 46.7, 0.818)
2	48.94	(.0290, 0.402, 14.7)	(8.70, 10.3, 71.0)	(10.8, 10.8, 56.6)	(16.0, 8.96, 48.4, 0.488)	(17.1, 13.9, 49.0, 0.480)
3	28.54	(0.230, 0.498, 13.1)	(6.98, 9.16, 29.5)	(7.26, 12.6, 36.2)	(36.1, 8.58, 33.0, 0.354)	(41.6, 12.8, 30.6, 0.406)
4	32.70	(0.210 0.326, 12.9)	(4.32, 9.72, 41.8)	(8.66, 8.80, 45.6)	(39.4, 8.54, 38.0, 0.356)	(52.5, 9.20, 33.0, 0.402)
5	29.42	(0.182, 0.314, 12.2)	(4.90, 11.6, 37.2)	(7.80, 11.7, 25.0)	(26.4, 9.30, 36.4, 0.322)	(34.1, 10.4, 36.7, 0.442)
6	4.040	(0.202, 0.240, 8.96)	(5.46, 6.88, 27.2)	(10.1, 11.5, 37.8)	(14.5, 5.56, 26.6, 0.396)	(7.74, 5.80, 3.96, 0.234)
7	14.36	(0.192, 0.378, 13.2)	(6.64, 10.1, 33.6)	(7.38, 12.9, 43.6)	(6.80, 10.3, 41.1, 0.336)	(5.82, 11.7, 26.1, 0.392)
8	48.20	(0.352, 0.338, 13.5)	(6.14, 8.76, 25.6)	(3.54, 8.72, 13.2)	(17.8, 6.92, 30.8, 0.392)	(14.9, 7.10, 26.9, 0.413)
A	61.6	(0.400, 0.608, 10.8)	(4.02, 3.30, 17.2)	(8.70, 14.6, 66.9)	(5.50, 3.44, 18.2, 18.0)	(4.42, 10.6, 36.0, 15.8)
B	60.0	(0.400, 0.800, 12.5)	(5.44, 8.92, 30.3)	(4.00, 16.0, 51.3)	(2.44, 13.3, 34.7, 14.3)	(7.96, 13.9, 40.9, 3.08)

表 6.3: 多重比較検定の結果 (補正 p 値)

	従来手法 1	従来手法 2	提案手法 1	提案手法 2	提案手法 3
従来手法 2	0.0614				
提案手法 1	0.0258	0.00709			
提案手法 2	0.0220	0.144	0.144		
提案手法 3	0.00012	0.0135	0.0220	0.00709	
提案手法 4	0.00280	0.01993	0.576	0.576	0.00451




図 6.1: 被験者 1 の頭皮上マッピング. 左から提案手法 1, 2, 3, 4 の頭皮上マッピングを表している.




図 6.2: 被験者 2 の頭皮上マッピング. 左から提案手法 1, 2, 3, 4 の頭皮上マッピングを表している.




図 6.3: 被験者 3 の頭皮上マッピング. 左から提案手法 1, 2, 3, 4 の頭皮上マッピングを表している.




図 6.4: 被験者 4 の頭皮上マッピング. 左から提案手法 1, 2, 3, 4 の頭皮上マッピングを表している.




図 6.5: 被験者 5 の頭皮上マッピング. 左から提案手法 1, 2, 3, 4 の頭皮上マッピングを表している.




図 6.6: 被験者 6 の頭皮上マッピング. 左から提案手法 1, 2, 3, 4 の頭皮上マッピングを表している.

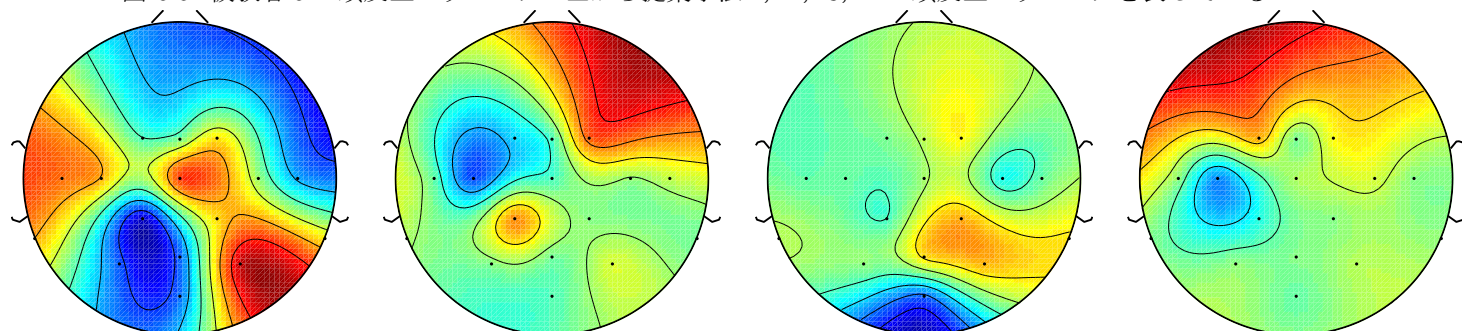


図 6.7: 被験者 7 の頭皮上マッピング. 左から提案手法 1, 2, 3, 4 の頭皮上マッピングを表している.




図 6.8: 被験者 8 の頭皮上マッピング. 左から提案手法 1, 2, 3, 4 の頭皮上マッピングを表している.

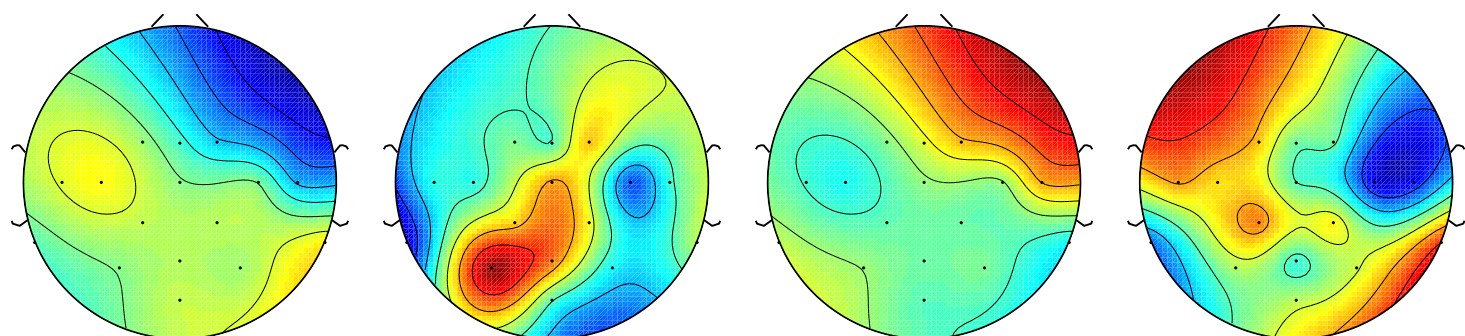


図 6.9: 被験者 A の頭皮上マッピング. 左から提案手法 1, 2, 3, 4 の頭皮上マッピングを表している.




図 6.10: 被験者 B の頭皮上マッピング. 左から提案手法 1, 2, 3, 4 の頭皮上マッピングを表している.

第7章 考察とまとめ

この章では、本実験で得られた結果について考察を行い、本論文で得られた成果についてまとめる。

7.1 結果の考察

識別の実験結果より、提案手法、特に提案手法3の識別結果が空間フィルタを用いない従来手法の識別結果と比べて11%ほど高いことと、どの被験者に対しても安定して識別率の向上が見られたことから本論文で提案したカーネル関数を用いた空間フィルタがP300-based BCIの識別に有効であることが示された。これらはカーネル関数を用いた特徴抽出がP300-based BCIに対して有効であったからだと考えられる。また、10人中9人の被験者で射影ノルムを用いた空間フィルタの方がよい結果が出ていることから、P300-based BCIには射影ノルムを用いた特徴抽出が有効であったと考えられる。

分散分析の結果より、有意水準5%で6群の母平均は等しくない、つまり、空間フィルタの手法の違いによって識別結果に差が出るということがわかった。そして、多重比較検定の結果から、特に提案手法3は本実験で比較する他の全ての手法と比べて補正 p 値が0.05よりも低いことがわかる。以上の結果と識別率の平均が本実験で比較する他のすべての手法と比べて高いことから、有意水準5%で提案手法3は本実験で比較する他の全ての手法よりも識別率の面で優れているということが統計的に示されたということがわかる。

手法ごとに最適パラメータの結果を見てみると、どのパラメータにも特有の傾向がないことがわかる。そのため、どの手法に対しても考えうる限りのパラメータで実験を行う必要があると考えられる。

頭皮上マッピングの結果から、頭頂部付近にある電極が特徴抽出に重要であることがわかった。また、数人の被験者で頭頂部でない部分、例えば前頭葉や後頭葉の部分にも特徴抽出に重要であるという結果が出ている。これは本実験では電極を設置していない前頭葉や後頭葉の付近に識別に重要な情報を含む電極が存在する可能性を示唆していると考えられる。

7.2 本論文の成果

本論文では、まずBCIの1つであるP300-based BCIについて述べ、その後に空間フィルタについて述べた。C-FMS beamformerでは信号の分離度合いを示す基準を用いて特徴抽出を行う手法である。一方、提案手法は観測信号にP300の特徴がどれくらい含まれているかを示す基準である射影ノルムや投影距離を用いて特徴抽出を行う手法である。また、カーネル関数を用いて、観測信号の分布が非線形な軸に沿って広がる場合に対しても有効で、かつ、各クラスの部分空間同士の重なりを減らすことができる空間フィルタも提案した。

識別実験では，提案手法の有効性を示した．特に提案手法3は，本実験で比較したどの手法よりも高い識別率であるということを統計検定で示した．

最後に頭皮上マッピングを行い，どの電極，または領域が特徴抽出に有効であったかを比較，検討した．

第8章 今後の課題

提案手法では、P300の信号だけに注目して部分空間を構成し、空間フィルタを構成したが、P300を含まない信号で構成した部分空間を基にした空間フィルタも原理的には有効であると考えられる。特に、カーネル関数を用いた空間フィルタに関しては、P300を含まない信号で構成した部分空間はP300の信号だけで構成した部分空間よりも、聴性BCIでは3倍、P300 spellerでは35倍の次元に拡張できる。この部分空間を用いれば、提案手法の結果を上回る可能性がある。しかし、部分空間を構成する際に用いる主成分分析の固有値分解を高次元で行わなければならないため、計算時間の大幅な増加が懸念される。具体的には、完全な固有値分解の計算コストは、 $D \times D$ の行列に対して $O(D^3)$ であり、 D が35倍されると計算コストは $35^3 = 42875$ 倍になる。そのため、高次元での主成分分析には、高次元に対して計算コストが少ないExpectation Maximization(EM)アルゴリズムを用いた主成分分析などの確率的成分分析やべき乗法などを用いる必要があると考えられる。また、現時点で通常の主成分分析とEMアルゴリズムによる主成分分析のどちらの計算時間が速いか比較検討する必要もあると考えられる。

投影距離を用いた手法の中に改良投影距離と呼ばれる手法がある。これは境界線付近での誤識別が多いという投影距離の短所を補うために考えられた手法である[28]。この改良投影距離を用いた空間フィルタを用いれば、提案手法2や4において、よい結果が出ると考えられる。

また、射影ノルムや投影距離を用いた手法の中に混合識別関数を用いたものがある[27]。これはある信号がどのクラスに属するかを識別する際に、類似する（類似しているとみなす）他クラスの信号の特徴を考慮し、類似するクラスに誤って識別されないようにする手法である。本実験で提案した手法にもこの手法の概念を取り入れればさらによい結果がでると考えられる。

本実験ではP300部分空間を構成する際にPCAを用いたが、部分空間を構成する手法は他にも存在する。例えば、Oriented PCAやRelative PCAなどである[32]。これらは部分空間を構成する際に注目したいクラスの特徴を強調し、かつ、他のクラスの特徴を抑制する部分空間を構成する。これらの手法をPCAの代わりにこれらの手法を用いることでより特徴抽出しやすい部分空間を構成できると考えられる。

提案手法3と4では、今回はカーネル関数としてRBFカーネルを用いたが、カーネル関数には他にも多項式カーネルやシグモイドカーネル、線形カーネルなどが存在する。また、カーネル関数はパラメータ次第で識別結果に大きな影響を及ぼす。そのため、本実験で用いなかったパラメータを用いた方がよい結果が出る可能性が十分にある。予備実験を行うなどしてある程度最適なカーネルやパラメータを見積もっておく必要があると考えられる。

本実験で提案したカーネル関数を用いた空間フィルタはカーネル関数を特徴抽出のみに用いた線形空間フィルタであったが、カーネル関数を用いれば、元の信号にカーネル関数を用いて非線形に拡張し、それに適応するための非線形空間フィルタを設計することも可能である。例えば、カーネル関数を用いればFC最大フィルタやSN比最大フィルタを非線形空間フィルタ

に拡張することも可能である。しかし、特徴抽出のみにカーネル関数を用いた提案手法と比べて、識別にかかる計算時間もさらに増えるため、全体的に計算時間が膨大になることが予想される。

本実験では従来手法2として C-FMS beamformer を用いたが、その他にも P300-based BCI 用の空間フィルタは提案されている。そのため、今後はそれらと提案手法を比較検討する必要があると考えられる。特に、教師ありの P300 用の空間フィルタと比較する必要がある。

本実験の結果では、投影距離を用いた空間フィルタは射影距離を用いた空間フィルタよりも全体的に識別率が低い傾向にある。しかし、聴性 BCI データセットを用いた予備実験では投影距離を用いた手法は正規化を用いない方が、正規化を用いるものよりもよい結果が出ていた。そのため、今後は事前に正規化を用いるか用いないかを検討する必要があると考えられる。

本実験では頭頂部付近に電極を集中させた電極配置であるため、頭頂部付近以外の頭皮上マッピングの精度は低くなってしまう。そのため、本実験に対して、前頭葉や後頭葉の付近に識別に重要な情報を含む電極が存在するかは疑わしい。頭皮上マッピングの精度を上げるため今後は、前頭葉や後頭葉の付近を含め、電極を頭に満遍なく設置した状態で実験を行う必要があると考えられる。もしくは、空間フィルタを求める際に正則化を加えて、マッピングの際に急激な高低差を発生させないようにする必要があると考えられる。正則化には [33] で提案されているような、電極間の距離を考慮した空間フィルタ用の正則化を用いることが望ましいと考えられる。

本実験は全てオフラインで行った。今後は実際に BCI の解析手法として実装し、うまく機能するか確かめる必要があると考えられる。その際に少しでも識別率を上げるため、また、被験者の負担を減らすために、BCI として機能するのに必要十分な信号の長さやチャンネル数、学習に必要な試行数などをあらかじめオフラインでの実験で確認する必要があると考えられる。

参考文献

- [1] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, “Brain-computer interfaces for communication and control,” *Clinical Neurophysiology*, vol. 113, no. 6, pp. 767-791, 2002.
- [2] 武田常広, “脳工学,” 電気情報通信学会 編, コロナ社, 2003.
- [3] H. Higashi, T. M. Rutkowski, Y. Washizawa, A. Cichocki, and T. Tanaka, “EEG auditory steady state responses classification for the novel BCI,” *33rd Annual International Conference of the IEEE EMBS*, Boston, Massachusetts, USA, pp. 4576-4579, August 2011.
- [4] M. Middendorf, M. McMillan, G. Calhoun, and K. S. Jones, “Brain computer interfaces based on the steady-state visual-evoked response,” *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 211-214, 2000.
- [5] 坂本 裕弥, 青野 雅樹, “脳波判別のための多次元時系列データ転移学習,” F10-2, DEIM Forram, 2010.
- [6] W. S. Pritchard, “Psychophysiology of P300,” *Psychological Bulletin*, vol. 89, no. 3, pp. 506-540, 1981.
- [7] 舟橋靖貴, 千鳥亮, 小阪将吾, 小口弘貴, 為末隆弘, 香山瑞恵, 橋本昌巳, 荒井 善昭 “BCIに用いる P300 導出のための聴覚刺激の検討,” 信学技報 MBE2008-27, pp. 61-66, 2008.
- [8] “BCI Competition,” <http://www.bbci.de/competition/>
- [9] B. Blankertz, K.-R. Mueller, D. Krusienski, G. Schalk, J. Wolpaw, A. Schloegl, G. Pfurtscheller, J. del R. Millan, M. Schroeder, and N. Birbaumer, “The BCI competition iii: Validating alternative approaches to actual BCI problems,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 14, no. 2, pp. 153-159, June, 2006.
- [10] L. A. Farwell and E. Donchin, “Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials,” *Electroencephalography and Clinical Neurophysiology*, vol. 70, No. 6, pp. 510-523, December, 1988.
- [11] G. Pires, M. Castelo-Branco, and U. Nunes, “Visual P300-based BCI to steer a wheelchair: A Bayesian approach,” Proc. 30th Annual International Conference of the IEEE EMBS, pp. 658-661, August, 2008.

- [12] G. Pires, U. Nunes, and M. Castelo-Branco, "Statistical spatial filtering for a P300-based BCI: Tests in able-bodied, and patients with cerebral palsy and amyotrophic lateral sclerosis," *Journal of Neuroscience Methods*, vol. 195, pp. 270-281, 2011.
- [13] B. Rivet and A. Souloumiac, "Optimal linear spatial filters for event-related potentials based on a spatio-temporal model: asymptotical performance analysis," *Signal Processing*, vol. 93, pp. 387-398, 2013.
- [14] 金谷 健一, "これなら分かる応用数学教室-最小二乗法からウェーブレットまで," 共立出版, 2003.
- [15] G. Pires, U. Nunes, and M. Castelo-Branco, "P300 spatial filtering and coherence-based channel selection," *Proceedings of the 4th International, IEEE EMBS Conference on Neural Engineering*, pp. 311-314, Antalya, Turkey, April 29 - May 2, 2009.
- [16] B. Nasihatkon, R. Boostani, and M. Z. Jahromi, "An efficient hybrid linear and kernel CSP approach for EEG feature extraction," *Neurocomputing* 73, pp. 432-437, 2009.
- [17] H. Alblawi and X. Song, "A Study of kernel CSP-based motor imagery brain computer interface classification," *Signal Processing in Medicine and Biology Symposium*, pp. 1-4, New York, December, 2012.
- [18] R. Courant and D. Hilbert, "Methods of Mathematical Physics," *Wiley*, 1953.
- [19] 池田 正幸, 田中 英彦, 元岡 達, "手書き文字認識における投影距離法," *情報学論*, vol.24, pp.106-112, 1983.
- [20] S. Watanabe, "Knowing & Guessing-Quantitative Study of Inference and Information," *John & Willey & Sons, Inc.*, 1969.
- [21] 前田 英作, 村瀬 洋, "カーネル非線形部分空間によるパターン認識," *電子情報通信学会論文誌. D-II, 情報・システム, II-パターン処理 J82-D-II(4)*, pp. 600-612, 1999.
- [22] B. Schölkopf, A. Smola, and K-R. Müller, "Nonlinear component analysis as a kernel eigenvalue problem," *Neural Computation*, vol. 10, pp. 1299-1319, 1998.
- [23] 山田剛史, 杉澤武俊, 村井潤一郎, "Rによるやさしい統計学," オーム社, 2012.
- [24] R. O. Duda, P. E. Hant, and D. G. Stork 原著, 尾上守夫 監訳, "パターン識別," 新技術コミュニケーションズ, 2007.
- [25] 入戸野 宏, "心理学のための事象電位ガイドブック," 北大路書房, 2005.
- [26] K. Fukunaga, "Introduction to Statistical Pattern Recognition. Second edition," *Morgan Kaufmann-Academic Press*. 1990.
- [27] 中島 考, 若林 哲史, 木村 文隆, 三宅 康二, "混合識別関数による類似文字認識の高精度化," *電子情報通信学会論文誌. vol. J83-D-II, No. 2*, pp. 623-633, 2月 2000.

- [28] 若林 哲史, 鶴岡 信治, 元岡 達, “手書き文字認識における投影距離法における特徴選択に関する考察,” 信学論, D-II, vol.J78-D-II, no. 11, pp. 1627-1638, Nov. 1995.
- [29] C. M. ビショップ 著, 元田 浩, 栗田 多喜男, 樋口 知之, 松本 裕治, 村田 昇 監訳, “パターン認識と機械学習 下,” シュプリンガー・ジャパン, 2008.
- [30] 林智幸, 新見直子, “厳格化の観点からの多重比較法の整理,” 広島大学大学院教育学研究科紀要第三部第 54 号, pp.189-196, 2005.
- [31] ”バイオインフォマティクス入門,” <http://bio-info.biz/>
- [32] Y. Washizawa, K. Hikida, T. Tanaka, and Y. Yamashita, “Kernel relative principal component analysis for pattern recognition, Structural, ” Syntactic, and Statistical Pattern Recognition, *Springer*, pp. 1105-1113, 2004.
- [33] 東 広志, A. Cichocki, 田中 聡久, “脳波電極間の距離情報を用いた正則化,” 第 26 回信号処理シンポジウム, B-11, 2011.